(51) Classification internationale des brevets C12N 15/48, C07K 14/15, C12Q 1/68, C07K 16/10, G01N 33/569

(11) Numéro de publication internationale:

WO 99/02696

A1

(43) Date de publication internationale: 21 janvier 1999 (21.01.99)

(21) Numéro de la demande internationale:

PCT/FR98/01442

(22) Date de dépôt international:

6 juillet 1998 (06.07.98)

(30) Données relatives à la priorité:

97/08815

7 juillet 1997 (07.07.97)

FR

(71) Déposant (pour tous les Etats désignés sauf US): BIO MERIEUX [FR/FR]; Chemin de l'Orme, F-69280 Marcy l'Etoile (FR).

(72) Inventeurs; et

- (75) Inventeurs/Déposants (US seulement): BESEME, Frédéric [FR/FR]; 39, rue de la Noyera, F-38090 Villefontaine (FR). BLOND, Jean-Luc [FR/FR]; 75 bis, rue des Acqueducs, F-69005 Lyon (FR). BOUTON, Olivier [FR/FR]; 48, avenue du Châter, F-69340 Francheville (FR). MANDRAND, Bernard [FR/FR]; 21, rue de la Doua, F-69100 Villeurbanne (FR), MALLET, François [FR/FR]; 84, rue Anatole France, F-69100 Villeurbanne (FR).
- (74) Mandataire: CABINET GERMAIN & MAUREAU; Boîte postale 6153, F-69466 Lyon Cedex 06 (FR).

(81) Etats désignés: AL, AM, AT, AU, AZ, BA, BB, BG, BR, BY, CA, CH, CN, CU, CZ, DE, DK, EE, ES, FI, GB, GE, GH, GM, GW, HR, HU, ID, IL, IS, JP, KE, KG, KP, KR, KZ, LC, LK, LR, LS, LT, LU, LV, MD, MG, MK, MN, MW, MX, NO, NZ, PL, PT, RO, RU, SD, SE, SG, SI, SK, SL, TJ, TM, TR, TT, UA, UG, US, UZ, VN, YU, ZW, brevet ARIPO (GH, GM, KE, LS, MW, SD, SZ, UG, ZW), brevet eurasien (AM, AZ, BY, KG, KZ, MD, RU, TJ, TM), brevet européen (AT, BE, CH, CY, DE, DK, ES, FI, FR, GB, GR, IE, IT, LU, MC, NL, PT, SE), brevet OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, ML, MR, NE, SN, TD, TG).

#### Publiée

Avec rapport de recherche internationale.

- (54) Title: ENDOGENETIC RETROVIRAL SEQUENCES, ASSOCIATED WITH AUTOIMMUNE DISEASES OR WITH PREG-NANCY DISORDERS
- (54) Titre: SEQUENCES RETROVIRAUX ENDOGENES, ASSOCIEES A DES MALADIES AUTO-IMMUNES ET/OU A DES PERTURBATIONS DE LA GROSSESSE

### (57) Abstract

The invention concerns a genomic retroviral nucleic material, in isolated or purified state, at least partially functional or non-functional, whereof the genome comprises a reference nucleotide sequence selected from the group including sequences SEQ ID Nos: 1 to 15, their complementary sequences, and their equivalent sequences, in particular the nucleotide sequences having, for every series of 100 contiguous monomers, at least 70 % and preferably at least 90 % homology with said sequences SEQ ID Nos: 1 to 15. The invention also concerns the application of said material.

#### (57) Abrégé

L'invention concerne un matériel nucléique de type génomique rétroviral, à l'état isolé ou purifié, au moins partiellement fonctionnel ou non fonctionnel, dont le génome comprend une séquence nuclééotidique de référence choisie dans le groupe incluant les séquences SEQ ID NOs: 1 à 15, leurs séquences complémentaires, et leurs séquences équivalentes, notamment les séquences nucléotidiques présentant, pour toute suite de 100 monomères contigus, au moins 70 % et préférentiellement au moins 90 % d'homologie avec respectivement lesdites séquences SEQ ID NOs: 1 à 15; et les applications de ce matériel.

# UNIQUEMENT A TITRE D'INFORMATION

Codes utilisés pour identifier les Etats parties au PCT, sur les pages de couverture des brochures publiant des demandes internationales en vertu du PCT.

ΑL	Albanie	ES	Espagne	LS	Lesotho	SI	Slovénie
AM	Arménie	FI	Finlande	LŤ	Lituanie	SK	Slovaquie
AT	Autriche	FR	France	LU	Luxembourg	SN	Sénégal
ΑÜ	Australie	GA	Gabon	LV	Lettonie	SZ	Swaziland
AZ	Azerbaidjan	GB	Royaume-Uni	MC	Monaco	TD	Tchad
BA	Bosnie-Herzegovine	GE	Géorgie	MD	République de Moldova	TG	Togo
BB	Barbade	GH	Ghana	MG	Madagascar	TJ	Tadjikistan
BE	Belgique	GN	Guinée	MK	Ex-République yougoslave	TM	Turkménistan
BF	Burkina Faso	GR	Grèce		de Macédoine	TR	Turquie
BG	Bulgarie	HU	Hongrie	ML	Mali	TT	Trinité-et-Tobago
BJ	Bénin	IE	Irlande	MN	Mongolie	UA	Ukraine
BR	Brésil	IL	Israël	MR	Mauritanie	UG	Ouganda
BY	Bélarus	IS	Islande	MW	Malawi	US `	Etats-Unis d'Amérique
CA	Canada	IT	Italie	MX	Mexique	UZ	Ouzbékistan
CF	République centrafricaine	JР	Japon	NE	Niger	CAL	Viet Nam
CG	Congo	KE	Kenya	NL	Pays-Bas	7.47	Yougoslavie
CH	Suisse	KG	Kirghizistan	NO	Norvège	ZW	Zimbabwe
Cī	Côte d'Ivoire	KP	République populaire	NZ	Nouvelle Zélande		
Ch.	Terneroun		démocratique de Corée	PL	Polon ·		
CN			Pás látique de Corée	PT	: .gal		
CU					manie		
CZ	Republic	LC			ideration do		
DE	Allemagne	LI	į.		Soud		
DK	Danemark	LK	S	<b>S</b> .	Suò		
T Tr	Estonie	LR	Liberia	5G	Singapour		

13

## SEQUENCES RETROVIRAUX ENDOGENES, ASSOCIEES A DES MALADIES AUTO-IMMUNES ET/OU A DES PERTURBATIONS DE LA GROSSESSE

La présente invention concerne un nouveau matériel nucléique, de type génomique rétroviral différents fragments nucléotidiques qui le comprennent ou qui sont obtenus à partir dudit matériel, ainsi que leur utilisation pour marquer au moins une maladie auto-immune, 10 ou une pathologie qui lui est associée, une grossesse pathologique ou un insuccès de grossesse.

5

15

20

25

30

35

Le criblage de la banque d'ADNc à l'aide de la sonde Ppol-MSRV (SEQ ID NO: 29) a permis de détecter des clones chevauchant permettant la reconstruction d'un ARN génomique putatif de 7582 nucléotides. -Par séquence reconstruite, on entend la séquence déduite l'alignement des clones chevauchants -. Cet ARN génomique présente la structure R-U5-gag-pol-env-U3-R. interrogation "blastn" sur plusieurs bases de données, à l'aide du génome reconstruit, montre qu'il existe une quantité importante séquences de génomiques (ADN) apparentées dans le génome humain. Environ 400 séquences ont été identifiées dans GenBank (cf figure 3) et plus de 200 séquences dans la banque EST (Expressed Sequence Tag), la plupart en antisens. Ces séquences sont trouvées sur plusieurs chromosomes, notamment les chromosomes 5, 7, 14, 16, 21, 22, X, avec une forte concentration apparente de LTR sur le chromosome X.

séquence reconstruite (ARNm) est contenue intégralement à l'intérieur du clone génomique RG083M05 (gb AC00064) (9,6 kb), et présente une similitude de 96% avec deux régions discontinues de ce clone qui contient également des régions répétées à chaque extrémité. L'alignement des séquences expérimentales correspondant aux régions 5' et 3' de l'ARN génomique reconstruit avec 1'ADN du clone RG083M05 a permis de déduire une séquence

LTR et d'identifier des éléments caractéristiques des rétrovirus notamment ceux impliqués dans la transcription inverse, à savoir le PBS (Primer Binding Site) en aval du LTR 5' et le PPT (PolyPurine Tract) en amont du LTR 3'. On observe que l'élément U3 est extrêmement comparaison de celui observé chez les rétrovirus de type C des mammifères, et comparable en taille à la région U3 généralement décrite chez les rétrovirus de type D et les rétrovirus aviaires. La région PBS est homologue au PBS l'utilisation aviaires, suggérant du 10 des rétrovirus tRNATrp comme amorce pour la transcription inverse. Par conséquent, cette nouvelle famille de HERV est nommée HERV-W (Human Endogenous RetroVirus).

L'analyse phylogénique dans la région pol a montré que la famille HERV-W est phylogéniquement liée aux familles ERV-9 et RTVL-H, et appartient donc à la famille des rétrovirus endogènes de type I. L'analyse phylogénétique de la trame de lecture ouverte (ORF) de env montre qu'elle est plus proche des rétrovirus simiens de 20 type D et des rétrovirus de la réticuloendothéliose aviaire que des rétrovirus mammifères de type C, suggérant une structure de génome chimérique C/D.

Les arbres phylogéniques, supportés par des hautes valeurs de "bootstrap" montrent que les familles ERV-9 et HERV-W dérivent de deux vagues d'insertions indépendantes. Ainsi, le(s) élément(s) actif(s) à l'origine de la famille HERV-W est (sont) distinct(s) de celui (ceux) du(des)quel(s) la famille ERV-9 dérive. De plus, le PBS de HERV-W utilise probablement un tRNA<sup>Trp</sup> alors que ERV-9 utilise probablement un tRNA<sup>Arg</sup>.

Enfin, les membres de la famille HERV-W sont exprimés dans le placenta, alors qu'on ne détecte pas les ARN ERV-9 dans ce tissu.

## FONCTIONS BIOLOGIQUES DE HERV-W

L'expression de HERV-W restreinte au placenta et la longue trame de lecture codant potentiellement pour une enveloppe rétrovirale autorisent à proposer des fonctions biologiques physiologiques dont l'altération pourrait être associée à des pathologies.

L'expression restreinte au placenta suggère que l'expression de gènes rétroviraux et/ou non rétroviraux sous la dépendance des LTR peut être hormone-dépendante. 10 Ces gènes peuvent être adjacents, ou sous la dépendance de LTR isolés. Une pathologie peut alors provenir d'une expression aberrante suite à la réactivation d'un LTR silencieux par divers facteurs : infection virale (par exemple par un membre de la famille des Herpèsvirus) ou activation immune locale. Un polymorphisme au niveau des LTR pourrait aussi favoriser ces événements.

15

20

25

30

35

L'enveloppe de HERV-W pourrait jouer un rôle fusogénique, en particulier au niveau de sous-types cellulaires du placenta. Le peptide immunosuppresseur de cette enveloppe pourrait protéger le foetus l'agression du système immunitaire maternel. Enfin, par un mécanisme de saturation de récepteurs, l'enveloppe de HERV-W pourrait jouer un rôle protecteur contre rétrovirales infections exogènes. L'altération l'immunité cellulaire locale peut découler d'un signal immunostimulateur porté par l'enveloppe. Cet effet peut être lié à une région portant une activité superantigène, ou à la région immunosuppressive qui deviendrait immunostimulatrice à la suite, soit d'un polymorphisme, soit d'un effet-dose (surexpression).

vérification de ces implications compréhension des conséquences liées à une altération des fonctions biologiques des LTR ou de l'enveloppe rétrovirale endogènes peut mener à l'établissement de méthodes de diagnostic ou de suivi :

- d'états de grossesse pathologique ou d'insuccès de grossesse,

- de maladies auto-immunes comme la sclérose en plaques ou la polyarthrite rhumatoïde.

5

15

30

Conformément à la présente invention, il a été endogène, un découvert. à l'état nouveau matériel et décrit explicité ci-après, nucléique, ayant d'un rétrovirus, susceptible d'être l'organisation et corrélé à une maladie auto-immune, ou une pathologie qui lui est associée, à une grossesse pathologique ou un 10 insuccès de grossesse.

Le matériel nucléique selon la présente invention, représente forme ARNm, environ 8 Kb, représenté à la Figure 1 et est décrit par SEQ ID NO: 11, et est représenté à la Figure 2 sous forme génomique.

Par l'expression "de type rétroviral", on entend la caractéristique selon laquelle le matériel nucléique considéré comprend une ou des séquences nucléotidiques 20 apparentées à l'organisation d'un rétrovirus, et/ou à ses séquences fonctionnelles ou codantes.

Ce matériel nucléique de référence s'apparente à un rétrovirus endogène humain, désigné par l'expression HERV-W. En conséquence, il peut être obtenu par toute 25 technique appropriée de balayage ("screening") de toute banque d'ADN humain, ou d'ADNc placentaire, comme montré ci-après, en particulier avec des amorces ou nucléiques synthétisées pour s'hybrider avec tout partie de SEQ ID NO: 11.

La présente invention concerne également tout produit nucléique ou peptidique, obtenu ou dérivé à partir du matériel nucléique de référence, selon SEQ ID NO: 11.

l'invention s'intéresse pour terminer différentes corrélations pouvant être faites entre le 35 matériel nucléique précité, et/ou ses produits dérivés, avec toute maladie auto-immune et/ou une pathologie qui lui est associée, ainsi qu'avec des cas de grossesse pathologique ou d'insuccès de grossesse.

Par dite "auto-immune", on entend notamment:

- la sclérose en plaques

5

15

35

- la polyarthrite rhumatoïde
- le lupus érythémateux disséminé
- le diabète insulino-dépendant
- et/ou les pathologies qui leur sont associées.

La présente invention concerne tout d'abord un matériel nucléique de type génomique rétroviral, à l'état isolé ou purifié, au moins partiellement fonctionnel ou non fonctionnel.

Ce matériel est caractérisé en ce que son génome comprend une séquence nucléotidique de référence choisie dans le groupe incluant les séquences SEQ ID NOs: 1 à 15, complémentaires, et leurs séquences séquences leurs nucléotidiques séquences notamment les équivalentes, présentant, pour toute suite de 100 monomères contigus, au moins 50% et préférentiellement au moins 70%, par exemple au moins 90% d'homologie avec respectivement lesdites séquences SEQ ID NOs: 1 à 15.

Ce matériel est également caractérisé en ce que son génome comprend une séquence nucléotidique de référence, codant pour tout polypeptide présentant, pour toute suite contigüe d'au moins 30 acides aminés, au moins 50%, et de préférence au moins 70% d'homologie avec une séquence peptidique susceptible d'être codée par au moins une partie fonctionnelle de la séquence nucléotidique de référence telle que définie ci-dessus.

A titre particulier, ce matériel comprend un fragment nucléique inséré entre deux séquences correspondant respectivement à la région LTR et au gène gag de la structure génomique rétrovirale, notamment un fragment nucléique constitué par ou comprenant la séquence SEQ ID NO: 12.

-25

L'invention concerne aussi un matériel nucléique de type rétroviral sous-génomique, constitué par une séquence nucléotidique identique à SEQ ID NO: 11, avec une tel qu'exemplifié par les clones cl.PH74 cl.PH7 (SEQ ID NO: 8) et cl.Pi5T (SEQ ID NO: 7), (SEQ ID NO: 9), cette délétion résultant ou non d'une stratégie d'épissage.

Le matériel nucléique précédemment défini comprend au moins une séquence nucléotidique fonctionnelle codant 10 pour au moins une protéine rétrovirale, et/ou au moins une séquence nucléotidique de régulation.

L'invention concerne ensuite tout fragment nucléotidique d'au moins 100 bases, comprenant une séquence nucléotidique choisie dans le groupe comprenant :

- a) toutes les séquences nucléotidiques, partielles et totales d'un matériel nucléique tel que défini précédemment
- b) toutes les séquences nucléotidiques, partielles et totales d'un clone choisi dans le groupe incluant les 20 clones:
- (SEQ ID NO: 1) - cl.6A2 - cl.6A1 (SEQ ID NO: 2) (SEQ ID NO: 3) - cl.7A16 (SEQ ID NO: 4) - cl.Pi22 (SEQ ID NO: 5) -c1.24.425 - cl.C4C5 (SEQ ID NO: 6) - cl.PH74 (SEQ ID NO: 7) - cl.PH7 (SEQ ID NO: 8) (SEQ ID NO: 9) - cl.Pi5T -cl.44.4(SEQ ID NO: 10) 30 (SEQ ID NO: 11) - HERV-W - cl.6A5 (SEQ ID NO: 12) (SEQ ID NO: 13) - cl.7A20 - cl.7A21 (SEQ ID NO: 14) (SEQ ID NO: 15) - LTR 35

15

- c) les séquences respectivement complémentaires aux séquences selon a) et b)
- d) les séquences respectivement équivalentes aux a) à c), notamment les séquences séquences selon 5 nucléotidiques présentant, pour toute suite de monomères contigus, au moins 50%, et de préférence au moins 70%, ou mieux au moins 80 %, par exemple au moins 90% d'homologie avec les séquences a) à c).

L'invention concerne aussi toute sonde nucléique 10 de détection d'un matériel nucléique, inséré ou non dans un acide nucléique, caractérisée en ce qu'elle est susceptible de s'hybrider spécifiquement sur un matériel nucléique, tel que défini précédemment.

Une telle sonde comprend ou non un marqueur.

L'invention concerne aussi une amorce nucléique pour l'amplification par polymérisation d'un ARN ou d'un ADN, caractérisée en ce qu'elle comprend une séquence nucléotidique susceptible de s'hybrider spécifiquement sur un matériel nucléique ou un fragment nucléique, tel que défini précédemment.

15

20

25

30

35

A titre d'exemple, une sonde nucléique ou amorce nucléique selon l'invention est caractérisée en ce qu'elle est constituée par une séquence nucléotidique choisie dans le groupe incluant SEQ ID NOs: 16 à 28.

L'invention concerne aussi tout ARN ou ADN, et notamment un vecteur de réplication, comprenant un fragment nucléotidique, tel que défini précédemment.

L'invention concerne aussi tout peptide codé par tout cadre de lecture ouvert appartenant à un fragment nucléotidique, tel que défini précédemment, notamment polypeptide, par exemple oligopeptide formant un déterminant antigénique reconnu par des sera de patients affectés par une maladie auto-immune, ou une pathologie qui lui est associée, ou de patientes ayant une grossesse pathologique ou un insuccès de grossesse.

A titre d'exemple, ce polypeptide est codé par un fragment nucléotidique comprenant un cadre de lecture ouvert codant pour une ou des protéines ENV rétrovirales.

Enfin, l'invention concerne :

5

10

15

20

25

35

- l'utilisation d'un matériel nucléique, ou d'un fragment nucléotidique, ou d'un peptide défini ci-dessus, tels que définis précédemment, comme marqueur moléculaire d'une maladie auto-immune ou d'une pathologie qui lui est de grossesse pathologique ou associée, d'insuccès grossesse ;
- l'utilisation d'un matériel nucléique, ou d'un fragment nucléotidique, tels que définis précédemment, comme marqueur chromosomique d'une susceptibilité à une maladie auto-immune ou d'une pathologie qui associée, ou d'un risque d'une grossesse pathologique ou d'un insuccès de grossesse ;
- l'utilisation d'un matériel nucléique, ou d'un fragment nucléotidique, tels que définis précédemment, comme marqueur de proximité d'un gène de susceptibilité à une maladie auto-immune ou à une pathologie qui lui est associée, ou à un risque d'une grossesse pathologique ou d'un insuccès de grossesse.

L'invention concerne aussi un procédé de marquage moléculaire d'une maladie auto-immune ou d'une pathologie lui est associée, de grossesse pathologique d'insuccès de grossesse, caractérisé en ce qu'on identifie et/ou quantifie dans tout matériel biologique corporel, notamment fluide corporel, tout fragment nucléotidique, tel que défini précédemment, soit sous forme d'ARN, soit 30 sous forme d'ADN.

titre d'exemple, selon un tel procédé, détecte dans ledit matériel biologique corporel, des cellules exprimant un fragment nucléotidique, tel défini précédemment.

L'invention concerne une application diagnostique et/ou thérapeutique d'un matériel nucléique, d'un fragment

nucléotidique ou d'un peptide défini ci-dessus, et en cela, un autre objet de l'invention est une composition diagnostique ou une composition thérapeutique comprenant undit matériel, undit fragment ou undit peptide.

5

Avant de détailler l'invention, différents termes utilisés dans la description et les revendications sont à présent définis:

- par virus humain, on entend un virus susceptible 10 d'infecter ou d'être hébergé par l'être humain,
- compte tenu de toutes les variations et/ou induites, recombinaisons naturelles ou pouvant rencontrées dans la pratique de la présente invention, les objets de cette dernière, définis ci-dessus et dans les 15 revendications, ont été exprimés en comprenant dérivés des différents matériels équivalents ou biologiques définis ci-après, notamment les séguences homologues nucléotidiques ou peptidiques,
- le variant d'un virus ou d'un agent pathogène et/ou infectant selon l'invention comprend au moins un 20 antigène reconnu par au moins un anticorps dirigé contre au moins un antigène correspondant dudit virus et/ou dudit agent pathogène et/ou infectant, et/ou un génome dont partie est détectée par au moins une 25 d'hybridation, et/ou au moins une amorce d'amplification nucléotidique spécifique dudit virus et/ou agent pathogène et/ou infectant, notamment un génome appartenant à conditions HERV-W. des d'hybridation famille dans déterminées bien connues de l'homme de l'art,
- selon l'invention, un fragment nucléotidique ou 30 polynucléotide oligonucléotide ou un un enchaînement de monomères, ou un biopolymère, caractérisé la séquence, informationnelle ou non, des acides nucléiques naturels, susceptible de s'hybrider à tout conditions fragment nucléotidique dans des 35 autre pouvant contenir prédéterminées, l'enchaînement

monomères de structures chimiques différentes et être obtenu à partir d'une molécule d'acide nucléique naturelle et/ou par recombinaison génétique et/ou par synthèse chimique; un fragment nucléotidique peut être identique à un fragment génomique d'un élément de la famille HERV-W considéré par la présente invention, notamment un gène de ce dernier, par exemple pol ou env dans le cas dudit élément;

- ainsi un monomère peut être un nucléotide 10 naturel d'acide nucléique, dont les éléments constitutifs sont un sucre, un groupement phosphate et une base azotée; dans l'ARN le sucre est le ribose, dans l'ADN le sucre est le désoxy-2-ribose; selon qu'il s'agit de l'ADN ou l'ARN. la base azotée est choisie parmi l'adénine, la quanine, 15 l'uracile, la cytosine, la thymine; ou le nucléotide peut être modifié dans l'un au moins des trois constitutifs; à titre d'exemple, la modification peut intervenir au niveau des bases, générant modifiées telles que l'inosine, la méthyl-5-20 désoxycytidine, la désoxyuridine, diméthylamino-5-désoxyuridine, la diamino-2,6-purine, la bromo-5-désoxyuridine et toute autre base modifiée favorisant l'hybridation; au niveau du sucre, modification peut consister dans le remplacement d'au 25 moins un désoxyribose par un polyamide, et au niveau du groupement phosphate, la modification peut consister dans son remplacement par des esters, notamment choisis parmi les esters de diphosphate, d'alkyl et arylphosphonate et de phosphorothioate,
- par "fonctionnel", on entend la caractéristique selon laquelle une séquence nucléotidique, un matériel nucléique, ou un fragment nucléotidique comprend une "une séquence informationnelle",
- par "séquence informationnelle", on entend toute 35 suite ordonnée de monomères, dont la nature chimique et l'ordre dans un sens de référence, constituent ou non une

information fonctionnelle de même qualité que celle des acides nucléiques naturels, par exemple une trame de lecture. codant protéine, une séquence pour une régulatrice, un site d'épissage, un site de recombinaison.

- par hybridation, on entend le processus au cours conditions opératoires appropriées, des dans notamment de stringence, deux fragments nucléotidiques, séquences suffisamment complémentaires, s'apparient pour former une structure complexe, notamment 10 double ou triple, de préférence sous forme d'hélice,

5

- une sonde comprend un fragment nucléotidique synthétisé notamment par voie chimique ou polymérisation, obtenu par digestion ou coupure enzymatique d'un fragment nucléotidique plus long, comprenant au moins six monomères, avantageusement de 10 à 100 monomères, préférence 10 à 30 monomères, et possédant une spécificité des conditions déterminées d'hybridation dans préférence, une sonde possédant moins de 10 monomères n'est pas utilisée seule, mais l'est en présence d'autres 20 sondes de taille aussi courte ou non ; dans certaines conditions particulières, il peut être utile d'utiliser des sondes de taille supérieure à 100 monomères ; une peut notamment être utilisée à des fins diagnostic et il s'agira par exemple de sondes de capture 25 et/ou de détection,
  - la sonde de capture peut être immobilisée sur un support solide par tout moyen approprié, c'est-à-dire directement ou indirectement, par exemple par covalence ou adsorption passive,
- la sonde de détection peut être marquée au moyen 30 les isotopes choisi notamment parmi enzymes notamment choisis parmi radioactifs, des peroxydase et la phosphatase alcaline et ceux susceptibles d'hydrolyser un substrat chromogène, fluorigène ou luminescent, des composés chimiques chromophores, des 35

composés chromogènes, fluorigènes ou luminescents, des analogues de bases nucléotidiques, et la biotine,

- les sondes utilisées à des fins de diagnostic de l'invention peuvent être mises en oeuvre dans toutes les techniques d'hybridation connues de l'homme de l'art, et techniques dites "DOT-BLOT", "SOUTHERN les notamment BLOT", "NORTHERN BLOT" qui est une technique identique à la technique "SOUTHERN BLOT" mais qui utilise de l'ARN comme cible, la technique SANDWICH; avantageusement, on utilise la technique SANDWICH dans la présente invention, comprenant une sonde de capture spécifique et/ou une sonde de détection spécifique, étant entendu que la sonde de capture et la sonde de détection doivent présenter une séquence nucléotidique au moins partiellement différente,

10

- toute sonde selon la présente invention peut s'hybrider in vivo ou in vitro sur l'ARN et/ou sur l'ADN, pour bloquer les phénomènes de réplication, notamment traduction et/ou transcription, et/ou pour dégrader ledit ADN et/ou ARN,
- une amorce est une sonde comprenant au moins six 20 et avantageusement de 10 à 30 monomères, des d'hybridation dans spécificité possédant une l'initiation déterminées, pour conditions polymérisation enzymatique, par exemple dans une technique la PCR (Polymerase d'amplification telle que 25 Reaction), dans un procédé d'élongation, tel séquençage, dans une méthode de transcription inverse ou analogue,
- deux séquences nucléotidiques ou peptidiques sont dites équivalentes ou dérivées l'une par rapport à l'autre, ou par rapport à une séquence de référence, si fonctionnellement les biopolymères correspondants peuvent jouer sensiblement le même rôle, sans être identiques, vis-à-vis de l'application ou utilisation considérée, ou dans la technique dans laquelle elles interviennent; sont notamment équivalentes deux séquences obtenues du fait de

la variabilité naturelle au sein d'un même individu, ou de la diversité naturelle d'un individu à un autre au sein d'une même espèce, notamment mutation spontanée de l'espèce à partir de laquelle elles ont été identifiées, ou induite, ainsi que deux séquences homologues, l'homologie étant définie ci-après,

- par "variabilité", on entend toute modification, spontanée induite d'une séquence, notamment et/ou substitution, et/ou insertion, délétion 10 nucléotides et/ou fragments de nucléotidiques, extension et/ou raccourcissement de la séquence à l'une au moins des extrémités; une variabilité non naturelle peut résulter des techniques de génie génétique utilisées, par exemple du choix des amorces de synthèse, dégénérées ou 15 non, retenues pour amplifier un acide nucléique; cette variabilité peut se traduire par des modifications de toute séquence de départ, considérée comme référence, et pouvant être exprimées par un degré d'homologie par rapport à ladite séquence de référence,
- 20 l'homologie caractérise le degré d'identité de deux fragments nucléotidiques ou peptidiques comparés; elle se mesure par le pourcentage d'identité qui est notamment déterminé par comparaison directe de séquences nucléoditiques ou peptidiques, par rapport à des séquences 25 nucléotidiques ou peptidiques de référence,
- ce pourcentage d'identité a été spécifiquement déterminé pour les fragments nucléotidiques, notamment clones relevant de la présente invention, et provenant d'un même individu; à titre d'exemple non limitatif, le 30 plus faible pourcentage d'identité observé entre les différents clones d'un même individu (cf SEQ ID NOs: 13 et 14) est d'au moins 90% et le plus faible pourcentage d'identité observé entre les différents clones de deux individus est d'au moins 80%,
- tout fragment nucléotidique est dit équivalent ou dérivé d'un fragment de référence, s'il présente une

séquence nucléotidique équivalente à la séquence du fragment de référence ; selon la définition précédente, sont notamment équivalents à un fragment nucléotidique de référence :

(a) tout fragment susceptible de s'hybrider au moins partiellement avec le complément du fragment de référence,

5

15

- (b) tout fragment dont l'alignement avec le fragment de référence conduit à mettre en évidence des 10 bases contigües identiques, en nombre plus important qu'avec tout autre fragment provenant d'un autre groupe taxonomique,
  - (c) tout fragment résultant ou pouvant résulter de la variabilité naturelle au sein d'un même individu, et de la diversité naturelle d'un individu à un autre dans la même espèce, à partir desquels il est obtenu,
  - (d) tout fragment pouvant résulter des techniques de génie génétique appliquées au fragment de référence,
- (e) tout fragment, comportant au moins huit 20 nucléotides contigus, codant pour un peptide homologue ou identique au peptide codé par le fragment de référence,
- (f) tout fragment différent du fragment de référence, par insertion, délétion, substitution d'au moins un monomère, extension, ou raccourcissement à l'une au moins de ses extrémités; par exemple, tout fragment correspondant au fragment de référence, flanqué à l'une au moins de ses extrémités par une séquence nucléotidique ne codant pas pour un polypeptide,
- par séquence nucléotidique, partielle ou totale,
   d'un matériel nucléique de référence, on entend également toute séquence associée par co-encapsidation, ou par coexpression, ou recombinée avec ledit matériel nucléique de référence,
- par polypeptide, on entend notamment tout 35 peptide d'au moins deux acides aminés, notamment oligopeptide, protéine, extrait, séparé, ou

substantiellement isolé ou synthétisé, par l'intervention de la main de l'homme, notamment ceux obtenus par synthèse chimique, ou par expression dans un organisme recombinant,

- par polypeptide codé de manière partielle par un 5 fragment nucléotidique, on entend un polypeptide présentant au moins trois acides aminés codés par au moins neuf monomères contigus compris dans ledit fragment nucléotidique,
- un acide aminé est dit analogue à un autre acide 10 aminé, lorsque leur caractéristiques physico-chimiques respectives, telles que polarité, hydrophobicité, et/ou basicité, et/ou acidité, et/ou neutralité, sont sensiblement les mêmes; ainsi, une leucine est analogue à une isoleucine,
- tout polypeptide est dit équivalent ou dérivé 15 d'un polypeptide de référence, si les polypeptides comparés ont sensiblement les mêmes propriétés, les notamment mêmes propriétés antigéniques. immunologiques, enzymologiques et/ou de reconnaissance moléculaire ; est notamment équivalent à un polypeptide de référence :
  - (a) tout polypeptide possédant une séquence dont au moins un acide aminé a été substitué par un acide aminé analogue,
- (b) tout polypeptide ayant une séquence peptidique équivalente, obtenue par variation naturelle ou induite dudit polypeptide de référence, et/ou du fragment nucléotidique codant pour ledit polypeptide,
  - (c) un mimotope dudit polypeptide de référence,
- 30 (d) tout polypeptide dans la séquence duquel un ou plusieurs acides aminés de la série L sont remplacés par un acide aminé de la série D, et vice versa,
- (e) tout polypeptide dans la séquence duquel on a introduit une modification des chaînes latérales des
   35 acides aminés, telle que par exemple une acétylation des

fonctions amines, une carboxylation des fonctions thiol, une estérification des fonctions carboxyliques,

- (f) tout polypeptide dans la séquence duquel une ou des liaisons peptidiques ont été modifiées, comme par sexemple les liaisons carba, rétro, inverso, rétro-inverso, réduites, et méthylène-oxy,
  - (g) tout polypeptide dont au moins un antigène est reconnu par un anticorps dirigé contre un polypeptide de référence,
- 10 le pourcentage d'identité caractérisant l'homologie de deux fragments peptidiques comparés est selon la présente invention d'au moins 80% et de préférence au moins 90%.
- Les expressions d'ordre utilisées dans la présente description et les revendications, telles que "première séquence nucléotidique" ne sont pas retenues pour exprimer un ordre particulier, mais pour définir plus clairement l'invention.
- Par détection d'une substance ou agent, on entend ci-après aussi bien une identification, qu'une quantification, ou une séparation ou isolement de ladite substance ou dudit agent.
- L'invention sera mieux comprise à la lecture de la description détaillée qui va suivre faite en référence aux Figures annexées dans lesquelles :
- la Figure 1 représente, d'une part, l'organisation du matériel rétroviral endogène découvert 30 selon la présente invention, sous la forme d'un ARNm génomique putatif, et, d'autre part, la localisation des clones mise en oeuvre selon la présente invention, par rapport à cette organisation; les échelles de longueur sont exprimées en Kb; les régions flanquantes (5' UTR et 3' UTR) sont indiquées dans des boîtes hachurées; les régions répétées dans ces deux régions flanquantes sont

indiquées par des flèches noires ; les régions correspondant aux gènes gag, pol, et env, sont indiqués respectivement, en noir, blanc et gris ; le positionnement de la sonde Ppol-MSRV est indiqué ;

5 - la Figure 2 représente une possibilité d'organisation génétique (ADN), illustrée par le clone RG083M05, et une stratégie d'épissage liant à cette séquence, les clones expérimentaux (ARNm); cette figure montre également les sites d'épissage observés par 10 référence à l'organisation rétrovirale; sur cette figure sont en outre indiqués:

la localisation des sondes utilisées (Pgag-LB19, Ppro-E, Ppol-MSRV et Penv-C15);

les sites donneurs (DS1 et DS2) et accepteurs (AS1 15 à AS3) d'épissage ;

les séquences provenant du clone RG083M05, dans les boîtes en minuscules, et les séquences dérivant des clones expérimentaux placentaires (ARNm), dans les boîtes en majuscule;

les ORFs putatives (ORF1, ORF2 et ORF3) ; et un insert de 2 Kb présent sous forme ADN mais non détecté sous forme ARN, représenté sous forme de hachures verticales.

Les autres conventions utilisées dans cette figure 25 sont les mêmes que celles de la Figure 1.

- la Figure 3 donne une représentation de clones génomiques (ADN) correspondant aux clones d'ADNc isolés ; sur cette figure, sont indiqués :

le pourcentage de similitude vis-à-vis de l'ARN 30 génomique reconstruit (ARN Recons) ;

la présence de séquences répétées à chaque extrémité de ces génomes (répétitions) ; et

la présence et la taille des trames de lecture ouverte (ORFs).

- la Figure 4 représente une analyse phylogénique identifiant la famille HERV-W.

- la figure 5 représente l'alignement des régions flanquantes 5' et 3' du clone RG083M05 avec les régions 5' et/ou 3' terminales de certains clones placentaires ; le tandem CAAC flanquant les LTR 3' et 5' est souligné la séquence LTR 5 doublement sous les séquences d'ADN, consensus de 783 pb (paires de bases) est indiqué au bas de l'alignement ; le PPT en amont de l'extrémité 5' de LTR et le PBS en aval de l'extrémité 3' de LTR sont indiqués ; régions U3R et U5 sont indiguées ; les correspondant à la fixation du facteur de transcription sont soulignés et numérotés de 1 à 6 ; la région -73 à 284 correspond à la séquence évaluée en "CAT assay" ; \* correspond à des sites putatifs de "capping" ; [polyA] indique le signal de polyadénylation.

- la Figure 6 représente une séquence putative d'un polypeptide d'enveloppe (ORF1) de HERV-W obtenu à partir de 3 clones d'ADNc placentaires différents ; le peptide leader (L), la protéine de surface (SU) et sont indiquées par des protéine transmembranaire (TM) flèches; le peptide de fusion hydrophobe et la région carboxy transmembranaire sont soulignés par un trait simple et un trait double, respectivement ; la région d'immunosuppression est signalée en italiques ; les sites potentiels de glycosylation sont indiqués par des points ; les acides aminés divergents sont indiqués sur la ligne inférieure ; la figure 6 présente également les trames de lecture ouverte correspondant à ORF2 et ORF3 tels que décrits à la Figure 2, et plus particulièrement leurs homologies avec les gènes de régulation rétroviraux.

30

35

25

10

15

Le matériel nucléique précédemment explicité a été protocole et caractérisé au terme du expérimental décrit ci-après, étant entendu protocole ne saurait limiter la portée de la présente invention et des revendications en annexe.

#### Exemple 1

15

# Isolement et séquençage de fragments d'ADNc chevauchants

- informations concernant l'organisation de Les 5 HERV-W ont été obtenues en testant une banque d'ADNc placentaire (Clontech cat#HL5014a) avec les Ppol-MSRV (SEQ ID NO: 29) et Penv-C15 (SEQ ID NO: 31) (cf Exemple 8), et en pratiquant ensuite une technique de 10 "gene walking" à l'aide des nouvelles séquences obtenues. Les expériences ont été mises en oeuvre en se référant aux préconisations du fournisseur de la banque. amplifications PCR sur ADN ont également été exploitées pour comprendre cette organisation.
  - Un certain nombre de clones ont été sélectionnés et séquencés, cf Figure 1:
    - Clone cl.6A2 (SEQ ID NO: 1) : région 5' non traduite de HERV-W et une partie de gag
- Clone cl.6A1 (SEQ ID NO: 2): gag et une partie 20 de pol
  - Clone cl.7A16 (SEQ ID NO: 3): Région 3' de pol
  - Clone cl.Pi22 (SEQ ID NO: 4): région 3' de pol et début de env
- Clone cl.24.4 (SEQ ID NO: 5) : ARN épissé 25 comprenant une partie de la région 5' non traduite de HERV-W, la fin de pol et la région 5' de env
  - Clone cl.C4C5. (SEQ ID NO: 6) : fin de env et région 3' non traduite de HERV-W
- Clone cl.PH74 (SEQ ID NO: 7) : ARN sous-30 génomique : région 5' non traduite de HERV-W, fin de pol, env, et région 3' non traduite de HERV-W
  - Clone cl.PH7 (SEQ ID NO: 8) : ARN multi-épissé : région 5' non traduite de HERV-W, fin de env et région 3' non traduite de HERV-W.
- Clone cl.Pi5T (SEQ ID NO: 9) : gène pol partiel et région U3-R

- Clone cl.44.4 (SEQ ID NO: 10) : région R-U5, gène gag et gène pol partiel.

A l'aide de ces clones, en procédant à des alignements de séquences, un modèle de séquence totale de 5 HERV-W a été élaboré. Les ARN épissés ont été mis en évidence ainsi que les sites potentiels donneurs et accepteurs d'épissage. L'ensemble de ces informations est montré à la Figure 2. Par étude de similitude avec des rétrovirus existants, les entités LTR, gag, pol et env ont 10 été définies.

L'organisation génétique putative de HERV-W sous forme ARN est la suivante (SEQ ID NO: 11):

gène 1..7582

Localisation des clones sur la séquence ARN génomique

15 reconstruite

cl.6A2 (1321 pb) 1-1325 ; cl.PH74 (535+2229= 2764 pb) 72-606 et 5353-

7582;

cl.24.4 (491+1457= 1948 pb); 115-606 et 5353-

20 6810;

cl.44.4 (2372 pb) 115-2496;

cl.PH7 (369+297= 666pb) 237-606 et 7017-7313;

cl.6A1 (2938 pb) 586-3559.;

cl.Pi5T (2785+566= 3351 pb) 2747-5557 et 7017-

25 7582;

cl.7A16 (1422 pb) 2908-4337;

cl.Pi22 (317+1689 = 2006 pb) 3957-4273 et

4476-6168;

cl.C4C5 (1116 pb) 6467-7582

30 5'LTR

1..120

/note="R of 5'LTR (extrémité 5'

incertaine"

121..575

/note="U5 of 5'LTR"

35 divers

579..596

/note="PBS primer binding site pour tRNA-W"

divers 606 /note="jonction d'épissage (site donneur d'épissage ATCCAAAGTG-GTGAGTAATA et site accepteur d'épissage CTTTTTCAG-ATGGGAAACG 5 clone RG083M05, GenBank accession AC000064)" 5353 divers /note="site accepteur d'épissage pour l'ORF1 (env)" 10 divers 5560 /note="site donneur d'épissage" 5581..7194 ORF /note="ORF1 env 538 AA" /produit-="enveloppe" 15 divers 7017 /note="site accepteur d'épissage pour ORF2 et ORF3" ORF 7039..7194 /note="ORF2 52 AA" ORF 7112..7255 20 /note="ORF3 48 AA" divers 7244..7254 /note="PPT polypurine tract" 3 LTR 7256..7582 /note-="U3-R of 3' LTR (jonction U3-R indéterminée) 25 divers 7563..7569

## 30 Exemple 2:

Identification de clones génomiques (ADN) correspondant aux clones d'ADN isolés

signal de polyadénylation

Une interrogation "blastn" sur plusieurs bases de 35 données, à l'aide du génome reconstruit, montre qu'il existe une quantité importante de séquences apparentées

dans le génome humain. Environ 400 séquences ont été identifiées dans GenBank et plus de 200 séquences dans la banque EST, la plupart en anti-sens. Les 4 séquences les plus significatives en taille et en similitude, illustrées sur la figure 3, sont les clones génomiques (ADN) suivants:

le clone humain RG083M05 (gb AC000064) dont la localisation chromosomique est 7q21-7q22,

le clone humain BAC378 (gb U85196, gb AE000660)

10 correspondant au locus alpha delta du récepteur des cellules T, localisé en 14q11-12,

le cosmide humain Q11M15 (gb AF045450) correspondant à la région 21q22.3 du chromosome 21,

le cosmide U134E6 (embl Z83850) sur le chromosome 15 Xq22.

La localisation des régions alignées pour chacun des clones est indiquée et l'appartenance à un chromosome est indiquée entre crochets. Le pourcentage de similitude (sans les larges délétions) entre les 4 séquences et l'ARN 20 génomique reconstruit est indiqué, ainsi que la présence de séquences répétées à chaque extrémité du génome et la taille des plus grandes trames de lecture (ORF). Des séquences répétées sont trouvées aux extrémités de 3 de séquence reconstruite est clones. La intégralement à l'intérieur du clone RG083M05 (9,6 Kb) et similitude de 96%. Cependant le présente une insertion de 2 Kb située présente une RG083M05 immédiatement en aval, de la région 5' non traduite (5' UTR). Cette insertion est également trouvée dans deux 30 autres clones génomiques qui présentent une délétion de 2,3 Kb immédiatement en amont de la région 3' non traduite (3' UTR). Aucun clone ne contient les trois trames de lecture (ORFs) gag, pol et env fonctionnelles. Le clone RG083M05 montre une ORF de 538 acides aminés 35 correspondant à une enveloppe entière. Le cosmide Q11M15 contient deux grandes ORFs contigües de 413 AA (trame 0)

et 305 AA (trame +1) correspondant à une polyprotéine pol tronquée.

## Exemple 3 Analyse phylogénique

Une analyse phylogénique a été réalisée au niveau des acides nucléiques sur 11 sous-régions différentes de l'ARN génomique reconstruit, et au niveau protéique sur 2 10 sous-régions différentes de env. Tous les arbres obtenus présentent la même topologie quelle que soit la région étudiée. Ceci est illustré à la Figure 4 au niveau des acides nucléiques dans les régions LTR et pol les plus conservées entre les séquences obtenues et ERV-9 et RTLV-Les arbres montrent clairement que 15 H. les séquences expérimentales décrivent une nouvelle famille distincte de ERV-9 et très distincte de RTLV-H comme souligné par l'analyse en "bootstrap". Ces séquences sont trouvées sur plusieurs chromosomes, notamment les chromosomes 5, 7, 14, 16, 21, 22, et X avec une forte concentration apparente de LTR sur le chromosome X.

La comparaison au niveau protéigue entre régions les plus conservées des protéines rétrovirales env famille HERV-W aue la est plus proche des 25 rétrovirus simiens de type D et des rétrovirus de la réticuloendothéliose aviaire que les rétrovirus mammifères de type C.

Ceci suggère une structure génomique chimère C/D.

30

20

5

# Exemple 4 Identification des éléments LTR, PPT et PBS

séquence reconstruite (ARN) contenue intégralement à l'intérieur du clone génomique RG083M05 (9,6 Kb) et présente une similitude de 96 % avec deux

régions discontinues de ce clone qui contient également des régions répétées à chaque extrémité. L'alignement des séquences expérimentales correspondant aux régions 5' et de l'ARN génomique reconstruit avec l'ADN du clone RG083M05 [5'(5-RG-28000-28872) et 3'(3-RG-37500-38314)] a permis de déduire une séquence LTR et d'identifier des éléments caractéristiques des rétrovirus, notamment ceux impliqués dans la transcription inverse, à savoir PBS en aval du LTR 5' et le PPT en amont du LTR 3' (cf Figure 5). On remarque que l'élément U3 est extrêmement court en 10 comparaison de celui observé chez les rétrovirus de type C des mammifères, et est comparable en taille à la région U3 généralement décrite chez les rétrovirus de type D et les rétrovirus aviaire. La région correspondant aux bases 2364 15 à 2720 du clone cl.PH74 (SEQ ID NO: 7) a été amplifiée par PCR et sous-clonée dans le vecteur pCAT3 (Promega) afin de l'évaluation de l'activité promotrice. réaliser activité significative a été trouvée dans des cellules HeLa par la méthode dite du "CAT assay" montrant fonctionnalité de la séquence promotrice du LTR. 20

La région PBS est homologue au PBS des rétrovirus aviaires.

25 Exemple 5

Organisation génétique et régulation de l'expression

Organisation sous forme ADN

Des amplifications PCR ont été réalisées sur des clones HERV-W entiers récupérés sur banque génomique humaine (voir exemple 1 pour le mode d'obtention), en utilisant les couples d'oligonucléotides suivants : U5 4992 (SEQ ID NO: 16), GAG 4619 (SEQ ID NO: 17)

35 GAG 4782 (SEQ ID NO: 18), POL 3167 (SEQ ID NO: 19) POL 3390 (SEQ ID NO: 20), POL 5144 (SEQ ID NO: 21) POL 5145 (SEQ ID NO: 22), U5 4991 (SEQ ID NO: 23).

PCR sont réalisées dans les conditions Les suivantes :

la concentration Oligonucléotides à dе 0,33 microMolaire

> Tampon TAQ polymérase Boerhinger 1X 0,5 unité de TAQ polymérase Boerhinger Mélange de dNTP à 0,25 mM chacun 0,5 mg d'ADN humain

Volume final 100 ml

10

35

Conditions de PCR (95°C, 5 min) x 1, (95°C, 30 sec + 54°C, 30 sec + 72°C 3 min) x 35.

Les produits de PCR ont ensuite été déposés sur gel d'agarose 1% pour être analysés après migration. 15 L'ensemble des PCR donne des fragments d'amplification de taille attendue, excepté pour la PCR LTR-4991--gag-4619 qui donne un fragment de taille supérieure d'environ 2 Kb par rapport à la taille attendue (déduite à partir des cDNA de la banque placentaire). La reconstitution 20 HERV-W sous forme ADN endogène représente donc une entité d'environ 10 Kb.

Après clonage, séquençage et analyse de la PCRon constate la présence d'une région gag-4619, d'insertion entre LTR et gag de SEQ ID NO: 12 25 cl.6A5). Cette région ne correspond pas à une région traditionnelle non traduite d'un rétrovirus : pas de région Ψ ni de PBS.

Les produits de PCR pol-3390, pol-5144 ont été également clonés et deux des clones obtenus ont séquencés. Le résultat de ces séquences est donné par les 30 clones cl.7A20 (SEQ ID NO: 13) et cl.7A21 (SEQ ID NO: 14). La comparaison de ces deux séquences nucléotidiques donne un score de 90% d'homologie pour la région concernée, montrant ainsi la variabilité de HERV-W chez un même individu.

HERV-W sous forme ADN est proposé la Figure 2.

Organisation générale : processus de transcription Les différents clones ADNc étant obtenus, des résultats acquis en PCR sur ADN, on déduit :

- une organisation ADN de 10 Kb possédant une séquence d'insertion de 2 Kb entre LTR et gag.

Le résultat de PCR sur ADN montrant la présence d'un insert de 2 Kb entre les régions LTR et gag suggère que les ADNc isolés dans le placenta proviennent de l'expression d'un génome de type RG083M05.

- une organisation ARN de 8 Kb résultant d'une transcription de 10 Kb suivie d'un épissage entre LTR et gag permettant de restaurer une continuité RF (Région Flanquante) 5' gag, et donnant ainsi un ARN de 8 Kb tel que mis en évidence en Northern Blot.

sondes (Pgag-LB19, SEQ ID NO: 30) Les gag protéase (Ppro-E, SEQ ID NO: 32) révèlent un ARN de taille voisine à 8 Kb, la sonde Penv-C15 (SEQ ID NO: 31) révèle en plus un ARN voisin de 3,1 Kb. Deux sondes définies dans la région 5' non traduite, obtenues par le criblage de la banque cDNA relaté ci-dessus (sonde P5'-gag-cl.6A2 dérivée du clone cl.6A2 et sonde P5'-envacl.24.4 dérivée du clone cl.24.4) révèlent les deux précédents ARN et un ARN d'environ 1,3 Kb. Cette distribution des ARNs est typique de transcrits de rétrovirus complexes : un ARN génomique codant pour gag-pro-pol, un ARN sous-génomique codant pour ARN multi-épissé(s) codant un/des et l'enveloppe, potentiellement pour des gènes de régulation.

La demie vie d'un tel ARN (LTR-R-U5-Insertion-GAG-30 POL-ENV-U3-R-HERV-W) est vraisemblablement très courte, car aucun ARN de 10 Kb n'est détecté en Northern Blot. Par analyse et comparaison de séquences, les sites potentiels donneurs (DS1 et DS2) et accepteurs (AS1 à AS3) d'épissage ont été définis et décrits dans la Figure 2.

5

10

15

20

25

# Exemple 6 Transcription dans des tissus sains

Différents tissus humains sains ont été testés par 5 une technique de Northern Blot (Human Multiple Tissue Northern Blot, Clontech cat# 7760-1), à l'aide des sondes (SEQ ID NO: 29), Pgag-LB19 (SEQ ID NO: 30), Penv-C15 (SEQ ID NO: 31), Ppro-E (SEQ ID NO: 32), P5'-gagcl.6A2 et P5'-env-cl.24.4, marquées comme décrit dans 10 l'exemple 1. Les expériences ont été réalisées en suivant des fabricants, recommandations autoradiographies ont été exposées 5 jours. L'analyse des résultats révèle des produits de transcription uniquement dans le placenta, et dans aucun des autres tissus humains 15 testés (coeur, cerveau, poumon, foie, muscle squelettique, rein et pancréas).

Par une technique de Dot Blot ARN (Clontech: Human RNA Master Blot Cat# 7770-1), et en utilisant le protocole expérimental préconisé par le fabricant, une quarantaine d'autres tissus, dont des tissus foetaux, ont été testés: seul le placenta donne une réponse spécifique après hybridation avec les sondes Pgag-LB19 (SEQ ID NO: 30) et Penv-C15 (SEQ ID NO: 31).

On constate qu'un signal est observé dans le rein 25 en Dot-Blot ARN, ce qui est infirmé par l'analyse en Northern Blot.

## Exemple 7

30

Identification d'un ARNm codant pour une enveloppe et les moyens de le détecter spécifiquement

Le criblage d'une banque d'ADNc placentaire à l'aide d'une sonde définie dans la région 5' non traduite 35 a permis d'isoler un ADNc défini par une région 5' non traduite (5' NTR), une jonction d'épissage, une séquence

codante, une région 3' non traduite (3' NTR) et une queue polyadénylée, cl.PH74 (SEQ ID NO: 7). Ce clone correspond à un ARN épissé codant pour une enveloppe. Par comparaison de séquences entre ce cDNA et le modèle de HERV-W endogène 2. on identifie une jonction selon Figure 5 proposé d'épissage sur l'ARNm, jonction d'épissage mettant en continuité la région 5' NTR et le gène env, conduisant à l'élaboration d'un ARN sous génomique épissé codant pour le gène d'enveloppe. Ces informations ont permis définir un oligonucléotide spécifique de cet ARNm, choisissant une localisation située sur le site d'épissage (Oligo 5307, selon SEQ ID NO: 24).

La mise en évidence de cette région de jonction permet d'établir un procédé de discrimination entre ARN et ADN rétroviral endogène, en utilisant dans une PCR un oligonucléotide défini sur cette région jonction, de notamment un oligonucléotide choisi dans le gène env (Oligo 4986, selon SEQ ID NO: 25).

PCR sont réalisées dans les conditions Les 20 suivantes:

à concentration de Oligonucléotides la 0,33 microMolaire

> Tampon TAQ polymérase Boerhinger 1X 0,5 unité de TAQ polymérase Boerhinger Mélange de dNTP à 0,25 mM chacun 0,5 mg d'ADN humain Volume final 100 ml

Sur 10 ADN différents testés, ce type de PCR n'a pas permis d'obtenir de produits d'amplification. ADNc issu d'ARN placentaire ou de cellules 30 contre sur cette PCR donne un exprimant HERV-W, Ce résultat confirme donc la nature d'amplification. spécifiquement ARN de ce fragment sous-génomique.

25

10

15

### Exemple 8

Identification de séquences codantes, contenues dans un ARNm spécifique

La stratégie d'épissage décrite dans l'exemple 5 est compatible avec la présence de trois trames de lecture ORF1 (SEQ ID NO: 33), ORF2 (SEQ ID NO: 34) et ORF3 (SEQ ID NO: 35) (cf Figure 6).

Le criblage d'une banque d'ADNc placentaire a 10 permis d'isoler un ADNc (SEQ ID NO: 7, cl.PH74) défini par 51 non traduite (5' NTR), une région une d'épissage, une séquence codante, une région traduite (3' NTR) et une queue polyadénylée. La séquence codante est de 538 acides aminés (SEQ ID NO: 33). analyses effectuées sur banques de données permettent de 15 mettre en évidence des caractéristiques d'une enveloppe complète. début de traduction rétrovirale : polyprotéine d'enveloppe, d'un peptide leader fortement hydrophobe d'environ 21 acides aminés, d'une protéine de surface SU, d'une protéine transmembranaire TM. Ces deux 20 entités protéiques présentent différents sites potentiels de glycosylation. Au sein de la protéine TM, on identifie une région immunosuppressive.

22 pb et 95 pb en amont du site accepteur 25 d'épissage, on a trouvé respectivement deux codons d'initiation susceptibles de diriger la synthèse de 52 AA (ORF2, SEQ ID NO: 34) et de 48 AA (ORF3, SEQ ID NO: 35). ORF2 consiste en une partie de l'extrémité carboxyterminale de env et ORF3 correspond à une traduction différente mais chevauchante.

Aucune homologie significative n'a été retrouvée par interrogation "blast". Cependant une interrogation LFASTA dans une sous-banque de donnée limitée aux Rétroviridae, ORF2 et ORF3 ont montré un pourcentage d'idendité de 35 % avec, respectivement, Rex du virus T-

lymphotrope humain et primate, et avec Tat du virus simien de l'immunodéficience.

### Exemple 9

5

# Complexité de la famille HERV-W

Le nombre de copies présentes dans le génome humain de chacune des séquences est évalué par une 10 technique de Dot Blot, à l'aide des sondes Pgag-LB19 (SEQ ID NO: 30), Ppro-E (SEQ ID NO: 32) et Penv-C15 (SEQ ID NO: 31).

Chacune des sondes est dénaturée et déposée sur une membrane Hybond N+ à raison de 2,5, 5, 10, 25, 50, 100 pg par dépôt. 0,5 mg d'ADN humain sont également 15 déposés sur la même membrane. Les membranes sont séchées 2 heures sous vide à 80°C. Les membranes sont ensuite hybridées avec la sonde déposée. Les techniques marquage des sondes, d'hybridation et de lavage des membranes sont les mêmes que pour le Southern Blot. Après 20 autoradiographie des membranes, on constate des niveaux d'intensité de signal proportionnels aux dépôts membrane. Après découpage des zones d'hybridation, comptage en scintillation est réalisé. Par comparaison 25 entre la gamme de dilution de la sonde déposée sur membrane et le résultat obtenu avec l'ADN humain, on peut évaluer le nombre de copie par génome haploïde de chacune des régions couvertes par les sondes :

- le nombre de gag endogène est évalué de 56 à 112 30 copies (76)
  - le nombre de protéase endogène est évalué de 166 à 334 copies (260)
  - le nombre de env endogène est évalué inférieur à 52 copies (13).
- Le criblage de 10<sup>6</sup> clones d'une banque d'ADN placentaire humain (Clontech cat# H15014b) a permis de

dénombrer 144 clones reconnus par la sonde Pgag-LB19, et 64 clones reconnus par la sonde Penv-C15. 13 clones hybridés conjointement par les sondes Penv-C15 et Pgag-LB19 ont été isolés, confirmant la présence de plusieurs copies d'un génome possédant à la fois gag et env, sans considération de fonctionnalité.

Le matériel nucléique, les séguences 10 nucléotidiques, les peptides ou protéines et lesdits matériels exprimées par **éventuellement** séquences, peuvent être utilisés pour détecter, prévoir, traiter et suivre toute maladie auto-immune, pathologies qui lui sont associées, ainsi que des cas de 15 grossesse pathologique ou d'insuccès de grossesse.

En effet, les données objectives et expérimentales permettent de relier rétrovirus et maladies auto-immunes et rétrovirus et perturbations de la grossesse :

- (1) des mécanismes communs sont mis en oeuvre dans 20 les pathologies rétrovirales et dans des maladies autoimmunes (présence d'auto-anticorps, de complexes immuns, infiltration cellulaire de certains tissus, troubles neurologiques).
- (2) des désordres pathologiques comparables à 25 certaines maladies auto-immunes apparaissent lors des infections par les rétrovirus HIV et HTLV (syndrome de Sjögren, lupus érythémateux disséminé, arthrite rhumatoïde...).
- (3) une activité transcriptase inverse a été détectée et des particules de type rétroviral ont été observées dans les surnageants de cultures cellulaires de patients atteints de sclérose en plaques (Perron et coll, Res. Virol. 1989; 140: 551-561 / Lancet 1991; 337: 862-863 / Res. Virol. 1992; 143: 337-350) ou de polyarthrite rhumatoïde.

- (4) des pathologies animales inflammatoires chroniques ou auto-immunes sont liées aux rétrovirus endogènes; certaines d'entre elles sont utilisées comme modèles animaux de maladies humaines (diabète insulino-5 dépendant, lupus érythémateux disséminé).
- taux, significatifs d'anticorps (5) des rétrovirus endogènes ont été décrits dans le cadre de ou inflammatoires; auto-immunes, systémiques d'autres données dans ce sens ont été communiquées par 10 plusieurs auteurs au IVème meeting européen sur octobre 1996). rétrovirus endogènes (Uppsala, Venables (communiqués du IVème meeting européen sur les rétrovirus endogènes, Uppsala, octobre 1996), on retrouve un taux d'anticorps anti-HERV-H significativement élevé pendant la grossesse mais aussi dans le cadre de divers désordres auto-immuns tels que le syndrome de Sjögren, le érythémateux disséminé ou la polyarthrite lupus toutefois qu'une preuve rhumatoïde, son sans implication directe puisse être apportée à ce jour.

15

20

25

L'implication des rétrovirus dans le phénomène le d'auto-immunité reste compatible avec caractère multifactoriel des maladies auto-immunes, systémiques ou inflammatoires qui confrontent des facteurs génétiques, hormonaux, environnementaux et infectieux.

Les particules observées dans les surnageants de cultures cellulaires de patients atteints de sclérose en plaques (Perron et coll, Res. Virol. 1989; 140: 551-561 / Lancet 1991; 337: 862-863 / Res. Virol. 1992; 143: 337-350) ou de polyarthrite rhumatoïde (données non publiées) peuvent résulter de l'expression: (i) d'un rétrovirus endogène compétent pour la réplication, (ii) de plusieurs rétrovirus endogènes défectifs coopérant par un phénomène de transcomplémentation ou (iii) d'un rétrovirus exogène.

Toutes ces observations permettent d'utiliser et considérer les matériels biologiques précédemment décrits, 35

comme marqueur d'une maladie auto-immune ou de perturbations de la grossesse.

En particulier, les techniques de marquage suivantes sont considérées :

- balayage du génome humain avec des sondes d'hybridation à forte stringence, dérivées du matériel nucléique précédemment décrit,
- amplification directe d'ADN génomique par PCR, en utilisant des amorces spécifiques pour la région 10 considérée
  - analyse des régions flanquantes de gènes cellulaires étrangers.

## REVENDICATIONS

1/ Matériel nucléique đе type génomique purifié, l'état isolé ou rétroviral, à partiellement fonctionnel ou non fonctionnel, dont le 5 génome comprend une séquence nucléotidique de référence incluant les le groupe séquences choisie dans SEQ ID NOs: 1 à 15, leurs séquences complémentaires, et séquences équivalentes, notamment les séquences nucléotidiques présentant, pour toute suite 10 monomères contigus, au moins 70% et préférentiellement au 90% d'homologie avec respectivement lesdites moins séquences SEQ ID NOs: 1 à 15.

2/ Matériel nucléique de type génomique purifié, l'état isolé ou au rétroviral, à moins 15 partiellement fonctionnel ou non fonctionnel, génome comprend une séquence nucléotidique de référence, codant pour tout polypeptide présentant, pour toute suite contigüe d'au moins 30 acides aminés, au moins 80%, et de préférence au moins 90% d'homologie avec une séquence peptidique susceptible d'être codée par au moins une partie fonctionnelle de la séquence nucléotidique de référence selon la revendication 1.

3/ Matériel nucléique de type génomique rétroviral revendications 1 l'une quelconque des 2, selon fragment nucléique inséré entre 25 comprenant un séquences correspondant respectivement à la région LTR et la structure génomique rétrovirale, gène gag de nucléique constitué par fragment ou notamment un comprenant la séquence SEQ ID NO: 12.

4/ Matériel nucléique de type rétroviral sousgénomique, constitué par une séquence nucléotidique identique à SEQ ID NO: 11, avec au moins une délétion, telle qu'une séquence choisie parmi SEQ ID NOs: 7 à 9.

5/ Matériel nucléique selon l'une quelconque des 35 revendications 1 et 4, comprenant au moins une séquence

nucléotidique fonctionnelle codant pour au moins une protéine rétrovirale.

- 6/ Matériel nucléique selon l'une quelconque des revendications 1 et 4, comprenant au moins une séquence nucléotidique de régulation.
  - 7/ Fragment nucléotidique d'au moins 100 bases, comprenant une séquence nucléotidique choisie dans le groupe comprenant :
- a) toutes les séquences nucléotidiques, partielles 10 et totales d'un matériel nucléique selon l'une quelconque des revendications 1 à 6
  - b) toutes les séquences nucléotidiques, partielles et totales d'un clone choisi dans le groupe incluant les clones :

15	_	cl.6A2	(SEQ	ID	NO:	1)
	-	cl.6A1	(SEQ	ID	NO:	2)
	-	cl.7A16	(SEQ	ID	NO:	3)
	_	cl.Pi22	(SEQ	ID	NO:	4)
	-	cl.24.4	(SEQ	ID	NO:	5)
20	-	cl.C4C5	(SEQ	ID	NO:	6)
	_	cl.PH74	(SEQ	ID	NO:	7)
	-	cl.PH7	(SEQ	ID	NO:	8)
	-	cl.Pi5T	(SEQ	ID	NO:	9)
	-	cl.44.4	(SEQ	ID	NO:	10)
25	_	HERV-W	(SEQ	ID	NO:	11)
	_	cl.6A5	(SEQ	ID	NO:	12)
	_	cl.7A20	(SEQ	ID	NO:	13)
	_	cl.7A21	(SEQ	ID	NO:	14)
	_	LTR	(SEQ	ID	NO:	15)

- 30 c) les séquences respectivement complémentaires aux séquences selon a) et b)
  - d) les séquences respectivement équivalentes aux séquences selon a) à c), notamment les séquences nucléotidiques présentant, pour teute suite de 100 monomères cc 4/2 15, 2 20%, et de 222rence au

moins 70%, par exemple au moins 90% d'homologie avec les séquences a) à c).

- 8/ Sonde nucléique de détection d'un matériel nucléique, inséré ou non dans un acide nucléique, 5 caractérisée en ce qu'elle est susceptible de s'hybrider spécifiquement sur un matériel nucléique, selon l'une quelconque des revendications 1 à 6, ou un fragment nucléique selon la revendication 7.
- 9/ Sonde selon la revendication 8, caractérisée en 10 ce qu'elle comprend un marqueur.
  - 10/ Amorce nucléique pour l'amplification par polymérisation d'un ARN ou d'un ADN, caractérisée en ce qu'elle comprend une séquence nucléotidique susceptible de s'hybrider spécifiquement sur un matériel nucléique selon l'une quelconque des revendications 1 à 6, ou un fragment nucléique selon la revendication 7.

15

20

- 11/ Sonde nucléique ou amorce nucléique caractérisée en ce qu'elle est constituée par une séquence nucléotidique choisie dans le groupe incluant SEQ ID NOS: 16 à 28.
- 12/ ARN ou ADN, et notamment vecteur de réplication, comprenant un fragment nucléotidique selon la revendication 7.
- 13/ Peptide codé par tout cadre de lecture ouvert appartenant fragment nucléotidique un selon 25 7, notamment polypeptide, par revendication oligopeptide formant un déterminant antigénique reconnu par des sera de patients affectés par une maladie autoimmune, ou une pathologie qui lui est associée, ou par des patientes ayant une grossesse pathologique ou un insuccès 30 de grossesse.
  - 14/ Peptide selon la revendication 13, caractérisé en ce qu'il est codé par un fragment nucléotidique comprenant un cadre de lecture ouvert codant pour une ou des protéines ENV rétrovirales.

15/ Utilisation d'un matériel nucléique selon les revendications 1 à 6, ou d'un fragment nucléotidique selon la revendication 7, ou d'un peptide selon la revendication 13 ou 14, comme marqueur moléculaire d'une maladie autoimmune ou d'une pathologie qui lui est associée, ou d'une grossesse pathologique ou d'un insuccès de grossesse.

16/ Utilisation d'un matériel nucléique selon les revendications 1 à 6, ou d'un fragment nucléotidique selon la revendication 7, comme marqueur chromosomique d'une susceptibilité à une maladie auto-immune ou d'une pathologie qui lui est associée, ou d'un risque d'une grossesse pathologique ou d'un insuccès de grossesse.

17/ Utilisation d'un matériel nucléique selon les revendications 1 à 6, ou d'un fragment nucléotidique selon la revendication 7, comme marqueur de proximité d'un gène de susceptibilité à une maladie auto-immune ou à une pathologie qui lui est associée, ou à un risque d'une grossesse pathologique ou d'un insuccès de grossesse.

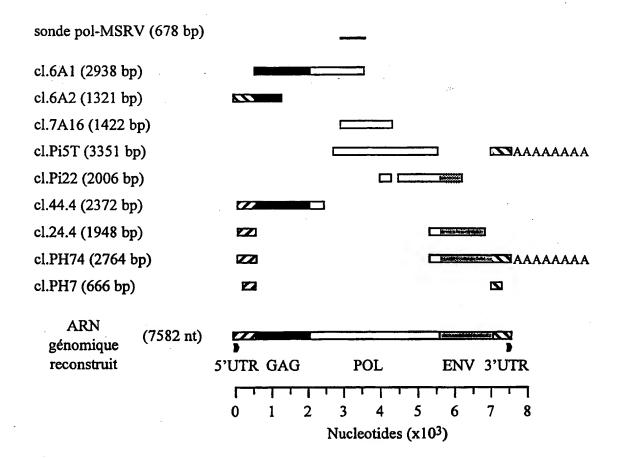
18/ Procédé de marquage moléculaire d'une maladie auto-immune ou d'une pathologie qui lui est associée, 20 d'un insuccès pathologique ou grossesse identifie qu'on et/ou caractérisé en ce grossesse, tout matériel biologique dans guantifie notamment fluide corporel, tout fragment nucléotidique selon la revendication 7, soit sous forme d'ARN, soit sous forme d'ADN.

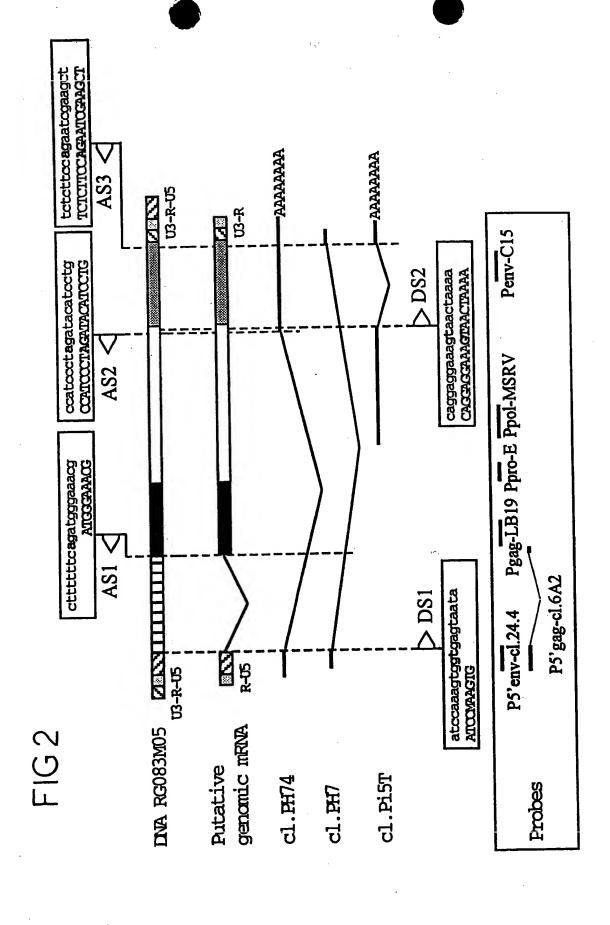
19/ Procédé selon la revendication 18, caractérisé en ce qu'on détecte dans ledit matériel biologique corporel, des cellules exprimant le fragment nucléotidique 30 selon la revendication.

20/ Composition diagnostique ou thérapeutique comprenant un matériel nucléique selon les revendications 1 à 6, ou un fragment nucléotidique selon la revendication 7, ou un peptide selon la revendication 13 ou 14.

10

## FIG 1





Recons       oui       9         3M05 [7]       96%       oui         78 [14]       88%       oui         115 [21]       89%       oui         E6 [x]       88%       non		<b>Q</b>			-Noms Sim	Similitudes	Répétitions	ORFs
——————————————————————————————————————	,			7582	ARN Recons		oui	238
— 14079 BAC378 [14] 88% oui — 27999 Q11M15 [21] 89% oui — 94627 U134E6 [x] 88% non	- ;		10.00	37879	_	%96	oni	538
27999 Q11M15 [21] 89% oui 94627 U134E6 [x] 88% non	ۍ .نا				BAC378 [14]	88%	oni	non
— 94627 U134E6 [x] 88% non	ن م			27999		%68	oui	413 et 30
	, <b>6</b>				U134E6 [x]	%88	nou	ron

FIG

FIG 4A

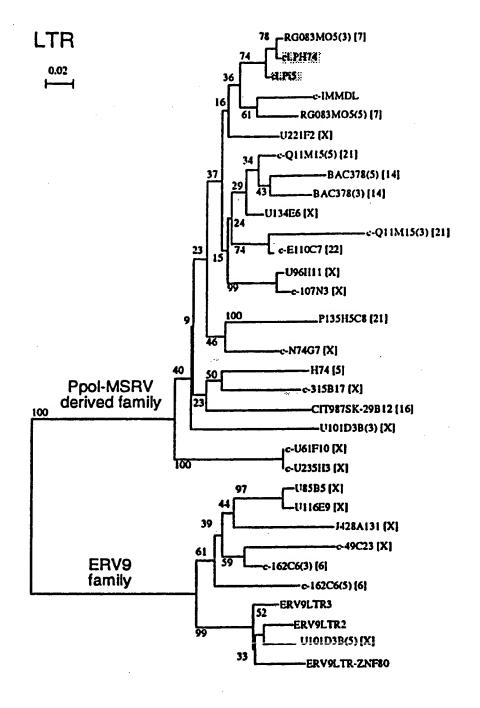


FIG 4 B

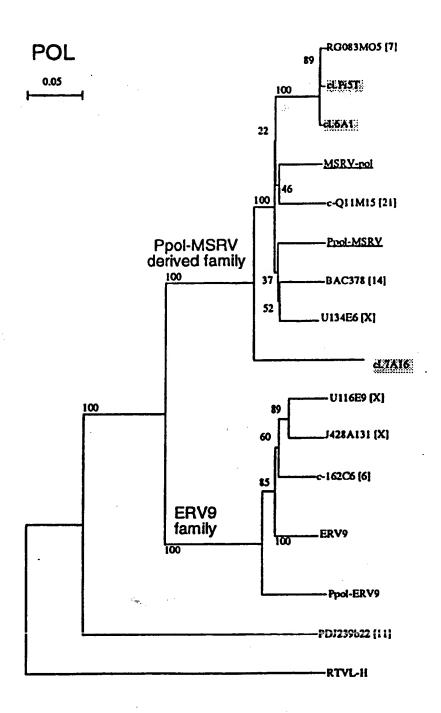
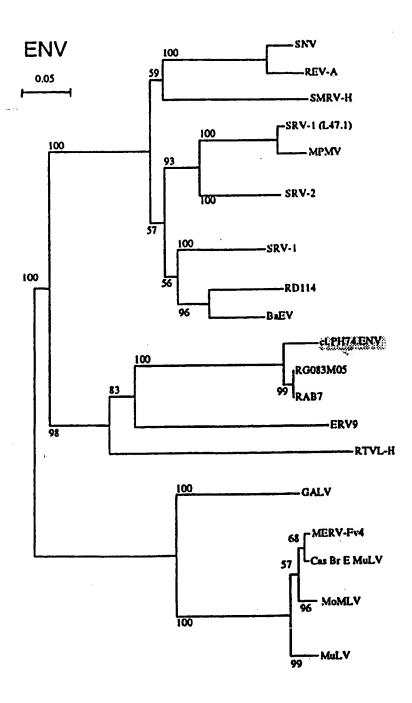


FIG 4C



# FIG 5A

زند	CCCTGGGGGGGGTTCCTTTCTGGGATGAGGGCAAAACGCCTGGAGATACACAATTATTCCAATTATTCCAAATTATTCCAAATTATT	
3-1 3755 314 5 1374.23 32 3-C4C5.71 136	TUGICGGCCAACACCAACAGCACACACACACACACTTAGGTTTTCCTGTGAGGGGGACTAGGGGGACTAGGTTGGGGGGGACTAGGCGGGACTAGGCGGGCCGACTAAGA CaattcagcaggaagcagttagAGGGGGGGCGAACCCCCAACACACACTTAGGTTTTCCTGTTGAGAGGGGACTAGAGAACAGGACTAGGACTAGGACTAGGCTGAGACTAAGA CaattcagcaggaagcagttagAGGGGCCAACCCCCAACACACACTTAGGTTTTCCTGTTGAGAGGGGACTAAGACAGGACTAGGTTTCCTAGGCTGAACAAGA	មិ ខេដ្ឋ
്യാണം	TGAGAGACAGAATTAGAATTAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAATTAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAGAATTAGAA	<u> </u>
	I I I I I I I I I I I I I I I I I I I	<b>6</b>
3-Ph. 2359	ATCCTAAGCTAGCTAGCTAACCTACTCCACCTTTAAACAGGGGGCTTGCAACTTAGCTCACCTGACCAATCAGAGGGCCTCACTAAAATGCTAATTAGGCAAAGACAGGAGT ATCCTTAAGCCTAAGCTAGGTGACCACACTTTAAACAGGGGGCTTGCAACTTAGCTCACCTGACCAATCAGAGAGGCTCACTAAAATGCTAATTAGGCAAAGACAGGAGGT ATCCTTAAGCCTAGGTGGGGAAGGTGACCACATCCACTTTAAACAGGGGGCTTGCAACTTAGCTCACCTGACCACATCAGAGAGGGGGGGAAAGACAGGAGGAAAGACAGGAGGTAAAATGCTAAATTAGGCAAAGACAGGAGTAACCCAAAAGCCTAAACACCTAAAGCCTAAGCCTAAGCTAAAATGCTAAATTAGGCAAAGACACAAAGACACAAAGACACAAAATGCTAAATTAGGCAAAAGACACAAAGACACAAAGACACAAAGACACAAAGACACAAAGACACAAAAGACACAAAAATGCTAAATTAGACAAAAGACACAAAAGACACAAAAATGCTAAAAATGCTAAAAATGCTAAAAAAAA	222
்.	ATCCTTAAGCCTAGSTGGGAAGGTGACCACRTCCACCTTAAAGACGGGGTTGCAACTTAGYTCACACCTGACCAAATCAGAGAGGTCAAATTAGGCAAAGACAGGAGGT  II	160
728000 5372 2750r 8314 3750r 8314 3765. 36 5-(-2.1-6. 36 7374.1-5	AAAGAAATAGCCAATCATCTATTGCCTGAGGGCACAGGAGGACAACAATCGGGATATAAACCCAGGCATTCGAGCTGGCAACAGCAGCCCCTTTGGGTCCTTTCCTTTGTATG AAAGAAATAGCCAATCATTATTGCCTGAGGACACAGGAGGACAATGATCGGGTTATAAACCCAAGGCCGGCAACGGCAACGGCA-ACCCCCTTTGGGTCCCTTTGTATG AAAGAAATAGCCAATCATTATTACCTGAGGAGGACAACGACAATGATCGGAACCAAAGTTTTCGAGCCGGCAACGGCA-ACCCCCTTTGGGTCCCTTTGTATG AAAGAAATAGCCAATCATTATTGCATGAGGACACAGCAGGAGGAAATGATCGGGAAAACCCAAGTTTTCGAGCCGGCAACGGCA-ACCCCCTTTGGGTCCCTTTGTATG AAAGAAATAGCCAATCATTTGCATGAGGACACAGCAGGAGGAAATGATCGGGAACCAAGTCTTCGAGCAGCACAGCACCCCTTTTGGGTCCCTTTTGTATG CAACAAATAGCCAAACCCTTTGCATCAGCACCAGCAGAGAATATTATAAACCCAAGTCTTGGAGCAGCACAGCACCCCTTTTGGGTCCCTTTTGTATG	347 332 359 359
. sensus.	ANG AAAGAATAGCCAATYTATTGCATGAGAGAGAGAGAGAAYRATCGGGATATAAACCCARGYHTTCGAGCYGGCAACRGCAGCCCCTTTGGGTCCCTTTGTAATAACTTTGTATG V	3.
\$ 39-28006	GGAGCTGITTICATGCTATITCACTCTATIAAATCTIGCAACTGCACTCTTCTGGTCCATGITTCTFACGGCTCGAGCTGAGCTTTIGCTCACGTCCACCACTGCTGTTTGCCACACGGTCCACCACTGCTGTTTGCCACACACA	465
5-6A2.1-600 5-7474.1-530 5-24.4.1-486	GGAGCTGTTTTCARGCTATTTCACTCTATTAAATCTTGCAACTGCGAAAAAAAA	<b>52 5 5 5 5 5 5 5 5 5 5</b>
Consensus	GGAGCICTGTITICATGCTATTICACTCTATTAAATCTTGCARCTGCTCTTCTGGTCCATTTACGCTTGTTGCTCACCACCACCACCACCACCACCACCACCACCACCACCA	۶ §

# FIG 5B

CCCAGACCTGCCCCTCACTCCCTCGATCCTGCATCCTGCAGGGTGCCGCTGTGCT CCCCAGACCTGCCGCTGACTCCCATCCTTGAATCTGCAGGGTGTGCTGCT CCCCAGACCTGCCGCTGACTCCCATCCTTGAATCTGCAGGGTGTGCTGCT CCCCAGACCTGCCGCTGACTCCCATCCTTGGAATCTGCAGGGTGTGCTGCT CCCCAGACCTGCCGCTGACTCCCATCCCTTGGAATCTGCAGGGTGTGCTGCT CCCCAGACCTGCCGCTGACTCCCATCCCTTGGAATCCTGCAGGGTGTCCAGGTTGTTCCAA ACGCTAAGTGCCTGGGTTTGTTCTAATTGACTGAACACTAGTCACTGGGTTCCAA ACGCTAAGTGCCTGGGTTTGTTCTAATTGACTGAACACTAGTCACTGGGTTCCAA ACGCTAAGTGCCTGGGTTTGTTCTAATTGACTGAACACTAGTCACTGGGTTCCAA ACGCTAAGTGCCTGGGTTTGTTCTAATTGACTGAACACTAGTCACTGGGTTCCAA ACGCTAAGTGCCTGGGTTTGTTCTAATTGACTGAACACTAGTCACTGGGTTCCAA ACGCTAAGTGCCTGGGTTTGTTCTAATTGACTGAACACTAGTCACTGGGTTCCAA ACGCTAAGTGCCTGGGTTTGTTCTAATTGACTGAACACTAGTCACTGGGTTCCAA ACGCTAAGTGCCTGGGTTTGTTCTAATTGACTGAACACTAGTCACTGGGTTCCAA ACGCTAAGTGCCTGGGTTTGTTCTAATTGACTGAACACTAGGTACACTGGGTTCCAA ACGCTAAGTGCCTGGGTTTGTTCTAATTGACTGAACACTAGGGTTCCAA ACGCTAAGTGCCTGGGTTTGTTCTAATTGACTGAACACACTAGGGTTCCAA ACGCTAAGTGCCTGGGTTTTGTTCTAATTGACTGAACACTAGGGTTCCAA ACGCTAAGTGCCTGGGTTTTTTTTTT			
COGCUMENCE CONTROLLES	5-RG-28000-28872 3-RG-37500-38314 5-6A2.1-600 5-PH74.1-530 5-24.4.1-486	COGCAGACCIGOCOSCIGACTOCCATOCTICGAATOCTICGAGGGTGTCCGCTGATOCTICAGGGGGGGGGCCCATTGGCGCTCCCAATTGGGGCTAGAGGCTTGCTGCCGCGCGGCGGGGGGGG	585 572 312 241 198
ACGCTAAGTCCTGGGTTTGTTCTAATTGACTGAACACTAGGTTCCATGGTTCTTCTGTGACCCAGGCTTCTAATAGACTATAAACACTACAAGGCCAAGGTT ACGCTAAGTCCTGGGTTTGTTCTAATTGACTGAACACTACTACTGGTTCTTCTGTGACCCAGGCTTCTAATAGACTATAAACACTACAAGGCCAAGATT ACGCTAAGTCCTGGGTTTGTTCTAATTGACTGAACACTACTACTGGTTCTTCTTGTGACCCAGGCTTCTAATAGACTATAAACACTACAAGGCCAAGATT ACGCTAAGTCCTGGGTTTGTTCTAATTGACTGAACACTACTACTACTACTACTACTACTACTACTACTACTA	Consensus	COSCANACCYSCOSCTISACTOCCATOCCTOTISSATCHTSCASSSTSTCCSCTISTSCTCCTGATCCAGGARGCRCCCATTISCCGCTCCCAATYGGGCTAAAGGCTTGCCATTISTNCCTGC	520
ANGCTAAGTOCCTGGGTTYRTYCTAATTGAGCAGACATANTCACTGGGTTCCACTCTTCTGTGAACGCCTCCTTCTAATTGAACACTTTGCGAACTCTTGGGAACTCTTGGAAGCGCTCTTGGAAGCGCCTCTTTGGAAGCGCTCTTGGAAGCGCTCTTGGAAGCGCTCTTGGAAGCGCTCTTGGAAGCGCTTTGCCACATCTTTGGAAGCCTTTGCCACATCTTTGGAAGCCTTTGCCACATCTTTGGAAGCCTTTGCCACATCTTTGGAAGCCTTTGCCACATCTTTGGAAGCCTTTGCCACATCTTTGGAAGCCTTTGCACACATCTTTGGAAACTCTTTGGAACTCTTTGCAACTCTTTGCAAACTCTTTGGAAACTCTTTGGAAACTCTTTGGAAACTCTTTGGAAACTCTTTGGAAACTCTTTGGAAACTCTTTGGAAACTCTTTGGAAACTCTTTGGAAGCTCTTTTTGCAAACTCTTTTGGAAACTCTTTTGGAAACTCTTTTTTTGCAAACTCTTTTTTTT	5-RG-28000-28872 3-RG-37500-38314 5-6A2.1-600 5-PH74.1-530 5-24.4.1-486	ACGGCTBAGTGCCTGGGTTTGTTCTBAGTGBAGCTGBAGTCACTGGGTTCCATGGTTCTTCTGTGBACCCACGGCTTCTBAGABCTGTBACACTTBACACTTBACACTTGGCCCAAGATT ATGGCTBAGTGCCTGGGTTTCTTAATTGAGCTGBACCACTGGTTCCATGGTTCTTCTTGTGACCCACGCTTCTBATAGAGCTTATBACACTCAATGGCCTAAGATT ACGGCTBAGTGCCTGGGTTTGTTCTBATTGAGCTGAACTAGTCACTGGGTTCCTTCTTGTGACCCACGGCTTCTBATAGAACTATBACACATGGCCCAAGATT ACGGCTBAGTGCCTGGGTTTGTTCTBATTGAGCTGAACTAGTCACTGGGTTCCTTCTTGTGACCCACGGCTTCTBATAGAACTTAACACTTAACACATGGCCCAAGATT ACGGCTBAGTGCCTGGGTTTGTTCTBATTGAGCTGAATCACTAGGGTTCCATGTGACCCACGGCTTCTGAATAGAACTTAACACTTAACACATGGCCCAAGATT	705 692 432 361 318
CCATTCCTTGGAATCCGTGAGGCCAA-GAACTCCAGGTCAGAGAATACGAGGCTTGCCACCATCTTGGAAGGGCCTGCTACCATCTTGGAAGTGGTTCACCACCATCTTGGGAAGTGGTTCACCACCATCTTGGGAAGTTCACCACCATCTTGGAAGTGGTTCACCACCATCTTGGGAAGTGGTTCACCACCACCATCTTGGGAAGTGGTTCACCACCATCTTGGGAAGTGGTTCACCACCACCATCTTGGGAAGTGGTTCACCACCACCATCTTGGGAAGTGGTTCACCACCACCATCTTGGGAAGTGGTTCACCACCACCATCTTGGGAAGTACACACCACCACCATCTTGGAAAGTGGTTCACCACCACCATCTTGGGAAGTACACACCACCACCATCACCACCACCACCACCACACACA	Consensus	AYGGCTAAGTGCCTGGGTTYRTYCTAATTGAGCTGAACACTANTCACTGGGTTCCATGGTTCTTCTTGTGACCCACRGCTTCTAATAGARCTATAACACTYACCRCATGGCCCAAGRTT	640
CONTROCTIGGAATCCETRARGSCAACGAACCCASGTCAGAAATACGARGCTTGCCACCATCTTGGAAGCGGCTTCACCACCATCTTGGAAGCTTCACCACCATCTTGGGAAGCTTGGAAGCTTGCAACCATCTTGGGAAGCTTGGAAGCTTGGAAGCTTGGAAGCTTTGGCAACCACCAACGAACCAACACATCTTGGCAACCAAC	5-RG-28000-28872 3-RG-37500-38314 5-6A2.1-600 5-FH74.1-530 5-24.4.1-486	CCATICCTIGGAAICCGTGAGGCCAA-GAACTCCAGGTCAGAGAATACGAGGCTTGCCACCATCTIGGAAGCGGCCTGCTACCAICTTGGAAGTGGTTCACCACCATCTTGGGAGCTCTG CCATTCCTTG-AATCCCATAAGGCCAA-GAACTCCAGGTCAGAAGAGGAGGCTTGCCACCATCTTGGAAGGGGCCTGCTTGGAAGTGGTTCACCACCATCTTGGGAGGTCTG CCATTCCTTGGAATCCGTGAGGCCAA-GAACTCCAGGTCAGAATACGAAGTTGCCACCATTGGAAGGGGCCTGCTTGGAAGTGGTTCACCACCATCTTGGGAAGTTCTTGGAAGTGGTTCACCACCATTTGGAAGTGGTTCACCACCATTTGGAAGTGGAATCCGTTGGAAGTGGTTCACCACCATTTGGAAGTGGAATCCGTTGGAAGTGGTTCACCACCATTTGGAAGTGGAATCCGTTGGAAGTGGAATCCCACCATTTGGAAGTGGAATCCGTTGGAAGTGGAATCCACCACCACCACCACCACCACCACCACCACCACCAC	824 766 551 481
18872 TGAGCAAGGACCCCCAAACATTTGGCAACCACGAACGGACATCCA 18914 TGAGCAAGGACCCCCAAACATTTTGGCAACCACGAACGGACATCCA 1GAGCAAGGACCCCCCGGTAACATTTTGGCAACCACGAACGGACATCC 1GAGCAAGGACCCCCCGGTAACATTTTGGCAACCACGAACGGACATCC 1GAGCAAGGACCCCCCGGTAACATTTTGGCAACCAACGGACATCCA 1GAGCAAGGACCCCCCGGTAACATTTTGGCAACCAACGGACATCCA 1GAGCAAGGACCCCCCGGTAACATTTTGGCAACCAACGGACATCCA 1GAGCAAGGACCCCCCGGTAACATTTTGGCAACCAACGGACATCCA 1GAGCAAGGACCCCCCGGTAACATTTTGGCAACCACAACGGACATCCA 1GAGCAAGGACCCCCCGGTAACATTTTGGCAACCACAACGGACATCCA 1GAGCAAGGACCCCCCGGTAACATTTTGGCAACCACAACGGACATCCA 1GAGCAAGGACCCCCCGGTAACATTTTGGCAACCACAACGGACATCCA 1GAGCAAGGACCCCCCGGTAACATTTTGGCAACCACAACGGACATCCAACAACAACAACAACAACAACAACAACAACAACA	Consensus	CCAITCCITGGAAICCRIFAARGSCAACGAACTCCASGICAGAAYACGARGCITGCCACCAICTTGGAAGCGGCCTGCTACCAICTTGGAAGTGGTTCACCACCAICTTGGAAGCTTCTG	760
	S-RG-28000-28872 3-RG-37500-38314 5-6A2.1-600 5-PH74.1-530 5-24.4.1-486		

8/9

# ORF1: ENV (538 AA) FIG (

< MGLPYH A	<b>L</b> IFLCSVLS FT V	PCFTLTAPPPCR S	<b>SU</b> CMTSSSPH Y		NIDAPSYRSI	LSKGTP C	60
TFTAHT	HMPRNCYH	SATLCMHANTHY	WTGKMINP	SCPGGLGVTVC	WTYFTQTGMS	SDGGGV	120
QDQARE	KHVKEVIS	QLTGVHGTSSPY R	KGLDLSKL	HETLRTHTRLV	• SLFNTTLTGI	LHEVSA	180
QNPTNC	WICLPLNF	RPYVSIPVPEQW	• NNFSTEIN	TTSVLVGPLVS	• NVEITHTSNI L	LTCVKF	240
SNTTYT		VTPPTQIVCLPS 	,	SAYRCLNGSSE	SMCFLSFLVI	PPMAIY T	300
TEQDLY		>< <b>TI</b> NKRVP <u>ILPFVIG</u>	-	rgiggittsto	FYYKLSQELN	IGDMER	360
VADSLV	rlqdqlns:	LA <i>AVVLQNRRAL</i> R	DLLTAERG S	GTCLELGEECC	YYVNQSGIVI	PEKVEE K	420
IPDRIQ	RIAEELRN' R	rgpwgllsr <u>wmp</u> O	WILPFLGPI	LAAIILLLLFG	PCIFDLLVNF N	VSSRI	480
EAVKLQI	ÆPKMQSK:	- FKIYRRPLDRPA	SPRSDVND	IKGTPPEEISA <i>I</i>		> \GSS	538

### ORF2 (52AA)

MEPKMQSKTKIYRRPLDRPVSPRSDVNDIKGTPPEEISAAQPLLRPNSAGSS-

#### Alignement ORF2 et Rex PLLV-L

ORF2 KIY-RRPLDRPASPRSDVNDIKGTPPEEISAAQPLLRP ++Y LD P SP ++ P S QPLLRP Rex PTLV-L (B53482) RLYNTLSLDSPPSPPKELPA----PSRFSPPQPLLRP

### ORF3 (48AA)

 ${\tt MLMTSKAPLLRKSQLHNLYYAPIQQEAVRAVVGQPPQQHLGFPVEMGD}$ 

#### Alignement ORF3 et Tat SIV-AGM

ORF3 MTSKAPLLRKSQLHNLYYAPIQQEAVRAVVGQPPQ +T AP R+ ++ L AP+Q +++ G+ Q Tat SIV-AGM(p05913) VTYHAPRTRKKIRSLNLAPLQHQSISTKWGRDGQ

#### LISTAGE DE SEQUENCES

(1) INFORMATIONS	GENERALES:
------------------	------------

5 (i) DEPOSANT:

15

30

- (A) NOM: BIO MERIEUX
- (B) RUE: CHEMIN DE L'ORME
- (C) VILLE: MARCY L'ETOILE
- (E) PAYS: FRANCE
- 10 (F) CODE POSTAL: 69280
  - (ii) TITRE DE L' INVENTION: MATERIEL NUCLEIQUE DE TYPE GENOMIQUE RETROVIRAL ENDOGENE, ASSOCIE A UNE MALADIE AUTO-IMMUNE ET/OU A DES PERTURBATIONS DE LA GROSSESSE ; UTILISATION EN TANT QUE MARQUEUR

(iii) NOMBRE DE SEQUENCES: 35

- (iv) FORME DECHIFFRABLE PAR ORDINATEUR:
  - (A) TYPE DE SUPPORT: Floppy disk
- 20 (B) ORDINATEUR: IBM PC compatible
  - (C) SYSTEME D' EXPLOITATION: PC-DOS/MS-DOS
  - (D) LOGICIEL: PatentIn Release #1.0, Version #1.30 (OEB)
- 25 (2) INFORMATIONS POUR LA SEQ ID NO: 1:
  - (i) CARACTERISTIQUES DE LA SEQUENCE:
    - (A) LONGUEUR: 1321 paires de bases
    - (B) TYPE: nucléotide
    - (C) NOMBRE DE BRINS: simple
    - (D) CONFIGURATION: linéaire
  - (ii) TYPE DE MOLECULE: ARNm (en ADN)
- 35 (iii) HYPOTHETIQUE: NON

#### (xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 1:

CAACAATCGG GATATAAACC CAGGCATTCG AGCTGGCAAC AGCAGCCCCC CTTTGGGTCC 60 CTTCCCTTTG TATGGGAGCT GTTTTCATGC TATTTCACTC TATTAAATCT TGCAACTGCA 120 CTCTTCTGGT CCATGTTTCT TACGGCTCGA GCTGAGCTTT TGCTCACCGT CCACCACTGC 180 10 TGTTTGCCAC CACCGCAGAC CTGCCGCTGA CTCCCATCCC TCTGGATCCT GCAGGGTGTC 240 CGCTGTGCTC CTGATCCAGC GAAGCGCCCA TTGCCGCTCC CAATTGGGCT AAAGGCTTGC 300 CATTGTTCCT GCACGGCTAA GTGCCTGGGT TTGTTCTAAT TGAGCTGAAC ACTAGTCACT 360 15 GGGTTCCATG GTTCTCTTCT GTGACCCACG GCTTCTAATA GAACTATAAC ACTTACCACA 420 TGGCCCAAGA TTCCATTCCT TGGAATCCGT GAGGCCAAGA ACTCCAGGTC AGAGAATACG 480 20 AAGCTTGCCA CCATCTTGGA AGCGGCCTGC TACCATCTTG GAAGTGGTTC ACCACCATCT 540 TGGGAGCTCT GTGAGCAAGG ACCCCCGGT AACATTTTGG CAACCACGAA CGGACATCCA 600 AAGTGATGGG AAACGTTCCC CGCAAGACAA AAACGCCCCT AAGACGTATT CTGGAAAATT 660 25 GGGAACAATT TGACCCTCAG ACACTAAGAA AGAAACGACT TATATTCTTC TGCAGTGCCG 720 CCTGGCACTC CTGAGGGAAG TATAAATTAT AACACCATCT TACAGCTAGA CCTCTTTTGT 780 30 AGAAAAGGCA AATGGAGTGA AGTGCCATAA GTACAAACTT TCTTTTCATT AAGAGACAAC 840 TCACAATTAT GTAAAAAGTG TGATTTATGC CCTACAGGAA GCCTTCAGAG TCTACCTCCC 900 TATCCCAGCA TCCCCGACTC CTTCCCCACT TAATAAGGAC CCCCCTTCAA CCCAAATGGT 960 35 CCAAAAGGAG ATAGACAAAA GGGTAAACAG TGAACCAAAG AGTGCCAATA TTCCCCAATT 1020

ATGACCCCTC CAAGCAGTGG GAGGAAGAGA ATTCGGCCCA GCCAGAGTGC ATGTGCCTTT 1080

TTCTCTCCCA GACTTAAAGC AAATAAAAAC AGACTTAGGT AAATTCTCAG ATAACCCTGA 1140

TGGCTATATT GGTGTTTTAC AAGGGTTAGG ACAATTCTTT GATCTGACAT GGAGAGATAT 1200

ATATGTCACT GCTAAATCAG ACACTAACCC CAAATGAGAG AAGTGCCACC ATAACTGCAG 1260

CCTGAGAGTT TGGCGATCTC TGGTATCTCA GTCAGGTCAA TGATAGGATG ACAACAGAGG 1320

A 1321

- 15 (2) INFORMATIONS POUR LA SEQ ID NO: 2:
  - (i) CARACTERISTIQUES DE LA SEQUENCE:
    - (A) LONGUEUR: 2938 paires de bases
    - (B) TYPE: nucléotide
    - (C) NOMBRE DE BRINS: simple
    - (D) CONFIGURATION: linéaire
  - (ii) TYPE DE MOLECULE: ARNm (en ADN)
- 25 (iii) HYPOTHETIQUE: NON

- (xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 2:
- CAACGACGGA CATCCAAAGT GATGGGAAAC GTTCCCCGCA AGACAAAAAC GCCCCTAAGA

  30

  CGTATTCTGG AGAATTGGGA CCAATTTGAC CCTCAGACAC TAAGAAAGAA ACGACTTATA 120

  TTCTTCTGCA GTGCCGCCTG GCACTCCTGA GGGAAGTATA AATTATAACA CCATCTTACA 180

  35 GCTAGACTTC TTTTGTAGAA AAGGCAAATG GAGTGAAGTG CCATAAGTAC AAACTTTCTT 240

TTCATTAAGA GACAACTCAC AATTATGTAA AAAGTGTGAT TTATGCCCTA CAGGAAGCCT 300 TCAGAGTCTA CCTCCCTATC CCAGCATCCC CGACTCCTTC CCCAACTAAT AAGGACCCCC 360 5 CTTCAACCCA AATGGTCCAA AAGGAGATAG ACAAAAGGGT AAACAGTGAA CCAAAGAGTG 420 CCAATATICC CCAATTATGA CCCCTCCCAA GCAGTGGGAG GAAGAGATTC GGCCCAGCCA 480 GAGTGCATGT GCTTTTTCTT CTCCCAGACT TAAAGCAAAT AAAAACAGAC TTAGGTAAAT 540 10 TCTCAGATAA TCCTGATGGC TATATTGATG TTTTACAAGG GTTAGGACAA TTCTTTGATC 600 TGACATGGAG AGATATAATG TCACTGCTAA ATCAGACACT AACCCCAAAT GAGAGAAGTG 660 15 CCACCATAAC TGCAGCCTGA GAGTTTGGCG ATCTCTGGTA TCTCAGTCAG GTCAATGATA 720 GGATGACAAC AGAGGAAAGA GATGATCCCC ACAGCCAGCA AGCAGTTCCC AGTCTASACC 780 CTCATTGGGG ACACAGAAAT CAGTAACATG GGAGATTGGT GCTGCAGACA TTTGCTAACT 840 20 TGTGTGCTAC AAGGACTAAG GAAAACTACG AAGAAAATCT ACGAATTACT CAATGATGTC 900 CACCATAACA CAGGGGAAGG GAAGAAAATC CTACTGCCTT TCTGGAGAGA CTAAGGGAGG 960 25 CATTGAGGAA GCGTGCCTCT CTGTCACCTG ACTCTTCTGA AGGCCAACTA ATCTTAAAGC 1020 GTAAGTTTAT CACTCAGTCA GCTGCAGACA TTAGAAAAAA CTTCAAAAGT CTGCCGTAGG 1080 CCCGGAGCAA AACTTAGAAA CCCTATTGAA CTTGGCAACY TCGGTTTTTT ATAATAGAGA 1140 30 TCAGGAGGAG CAGGCGGAAC AGGACAAACG GGATTAAAAA AAAGGCCACC GCTTTAGTCA 1200 TGACCCTCAG GCAAGTGGAC TTTGGAGGCT CTGGAAAAGG GAAAAGCTGG GCAAATTGAA 1260 35 TGCCTAATAG GGCTTGCTTC CAGTGCGGTC TACAAGGACA CTTTAAAAAA GATTGTCCAA 1320

GTAGAAGTAA GCCGCCCCTT CGTCCATGCC CCTTATTTCA AGGGAATCAC TGGAAGGCCC 1380 ACTGCCCCAG GGGACAAAGG TCTTTTGAGT CAGAAGCCAC TAACCAGATG ATCCAGCAGC 1440 5 AGGACTGAGG GTGCCTGGGG CAAGCGCCAT CCCATGCCAT CACCCTCACA GAGCCCTGGG 1500 TATGCTTGAC CATTGAGGGC CAGGAAGGTT GTCTCCTGGA CACTGGTGCG GTCTTCTTAG 1560 TCTTACTCTT CTGTCCCGGA CAACTGTCCT CCAGATCTGT CACTATCTGA GGGGGTCCTA 1620 10 AGACGGGCAG TCACTAGATA CTTCTCCCAG CCACTAAGTT ATGACTGGGG AGCTTTATTC 1680 TTTTCACATG CTTTTCTAAT TATGCTTGAA AGCCCCACTA CCTTGTTAGG GAGAGACATT 1740 15 CTAGCAAAAG CAGGGGCCAT TATACACCTG AACATAGGAG AAGGAACACC CGTTTGTTGT 1800 CCCCTGCTTG AGGAAGGAAT TAATCCTGAA GTCTGGGCAA CAGAAGGACA ATATGGACGA 1860 GCAAAGAATG CCCGTCCTGT TCAAGTTAAA CTAAAGGATT CCACTTCCTT TCCCTACCAA 1920 20 AGGCAGTACC CCCTCAGACC CAAGGCCCAA CAAGGATTCC AAAAGATTGT TAAGGACTTA 1980 ANAGCCCAAG GCTTAGTAAA ACCATGCATA ACTCCCTGCA GTAATTCCGT AGTGGATTGA 2040 25 GGAGGCACAG AAACCCAGTG GACAGTGGAG GGTTAGTGCA AGATCTCAGG ATTATCAATG 2100 GAGGCCGTTG TCCTTTTATA CCCAGCTGTA CCTAGCCCTT ATACTGTGCT TTCCCAAATA 2160 CCAGAGGAAG CAGAGTGGTT TACACTCCTG GACCTTAAGG ATGCCTTCTT CTGCATCCCT 2220 30 GTACATCCTG ACTCTCAATT CTTGTTTGCC TTTGAAGATA CTTCAAACCC AACATCTCAA 2280 CTCACCTGGA CTGTTTTACC CCAAGGGTTC AGGGATAGCC COCATCIATT TOGGCCAGGCA 2340 35 TTAGCCCAAG ACTTGAGCCA ATCCTCAPAC CTGGACACTT GTCCTTCGGT AGGTGGATGA 2400

TTTACTTTE GCCGCCCATT CAGAAACCTT GTGCCATCAA GCCACCCAAG CGCTCTTCAA 2460

TTTCCTCGCT ACCTGTGGCT ACATGGTTTC CAAACCAAAG GCTCAACTCT GCTCACAGCA 2520

5 GGTTACTTAG GGCTAAAATT ATCCAAAGGC ACCAGGGCCC TCAGTGAGGA ACACATCCAG 2580

CCTATACTGG CTTATCCTCA TCCCAAAACC CTAAAGCAAC TAAGGGGATT CCTTGGCGTA 2640

ATAGGTTTCT GCCGAAAATG GATTCCCAGG TTTGGCGAAA TAGCCAGGTC ATTAAATACA 2700

CTAATTAAGG AAACTCAGAA AGCCAATACC CATTTAGTAA GATGGACAAC TGAAGTAGAA 2760

GTGGCTTTCC AGGCCCTAAC CCAAGCCCCA GTGTTAAGTT TGCCAACAGG GCAAGACTTT 2820

15 TCTTCATATG TCACAGAAAA AACAGGAATA GCTCTAGGAG TCCTTACACA GATCCGAGGG 2880

ATGAGCTTGC AACCTGTGGC GTACCTGACT AAGGAAATTG ATGTAGTGGC AAAGGGTT 2938

- 20 (2) INFORMATIONS POUR LA SEQ ID NO: 3:
  - (i) CARACTERISTIQUES DE LA SEQUENCE:
    - (A) LONGUEUR: 1422 paires de bases
    - (B) TYPE: nucléotide
- 25 (C) NOMBRE DE BRINS: simple
  - (D) CONFIGURATION: linéaire
  - (ii) TYPE DE MOLECULE: ARNm (en ADN)
- 30 (iii) HYPOTHETIQUE: NON
  - (xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 3:
- TCAGGGATAG CCCCCATCTA TTTGGCCAGG CATTAGCCCA AGACTTGAGT CAGTTATCAT 60

  35

  ACCTGGACAC TCTTGTCCTT CAGTATGTGG ATGATTTACT TTTAGCTGCC TGTTCAGAAA 120

CCTTGTGCCA TCAAGCCACC CAAGCACTCT TAAATTTCCT CGCCACCTGT GGCTACAAGG 180 TTTCCAAAGA GAAGCTCAGC TCTGCTCACA GCAGGTTAAA TACTTAGGAC TAAGATTATC 240 5 CAAAGGCACC AAGGCCCTCA GTGAGGAATG TATCCAGCCT ATACTGGCTT ATCCTCATCT 300 CAAAACCCTA AAGCAACTAA GAGAGTTCCT TGGCATAACA GGCTTCTGCC GAATATGGAT 360 10 TCCCCAGGTA TGGCAAAATA GCCAGGCCAT TATATACAGT AATTAAGGAA ACTCAGAAAG 420 CCAATACCCA TTTAATAAGA TGGATACCTG AAGCCAAAGT GGCTTTCCAG GCCCCTAAAG 480 AAGGCCTTAA ACCCAAGTCC CAGTGTTAAG CTTGCCAACG GGGCAAGACT TTTCTTTATA 540 15 CATCACAGAA AAAAACAGAA ACAGCTCTGG GAGTCCTTAC ACAGGTCCAA GGGACGAGCT 600 TGCAACCCAT GGCATACCTG AGTAAGGAAA CTGATGTAGT GGCAAAGGGT TGGCTTCATT 660 20 GTTTATGGGT AGTGGTGGCA GTAGCAGTTG TAGTATCTGA AGCAGTTAAA ATAATACAGG 720 GGAGAGATCT TACTGTGTGG ACATCTCATG AGGTGAACAG CATACTCACT GCTAAAGGAG 780 ACTTGTGGCT GTCAGACAAC CGTTTACTTA AATATCAGGC TCTATTACTT GAAAGGCCAG 25 TGCTGCAACT GTGCACTTGT GCAACTCTTA ACCCAGTCNC ATTTCTTCCA GACAATGAAG 900 ATAGAATATA ACTGTCAACA AATAATTTCT CAAACCTATG CCACTCGAGG GGACCTTCTA 960 30 GAAGTTCCCT TGACTGATCC TGACCTTCAA CTTGTATACT GATGGAAGTT CCTTTGTAGA 1020 ANANGGACTT CANANGCGGG GTATGCAGTG GTCAGTGATA ATGGAATATT TGANAGTATC 1080 CCCTCACTCC AGGAACTAGT GCTTAGCTGG CAGAACTAAT AGCCTTCATT GGGGCACTAG 1140 35 AATTAGGAGA AGGAAAAAGG GTAAATATAT ATACAGACTC TGAGTATGCT CACCTAGTCN 1200

	TCCATGCCCA	TGAGGCAATA	TGCAGAGAAA	GGGAATTCCT	AACTTCCGAG	GGAACACCTA	1260
5	TCACACATCA	GGAAGCCATT	AGGAGATTAT	TACTGGCAGT	ACAGAAACCT	AAAGAGGTGG	1320
,	AAGTCTTACA	CTGCTGGGGT	CATCAGAAAG	GAAAGAAAAG	GGAAATAGAA	GGGAATTGCC	1380
	AAGCAGATAT	TGAAGCAAAA	AGAGCTGCAA	GGCAGGACCC	TC		1422

10

- (2) INFORMATIONS POUR LA SEQ ID NO: 4:
  - (i) CARACTERISTIQUES DE LA SEQUENCE:
    - (A) LONGUEUR: 2006 paires de bases
- 15 (B) TYPE: nucléotide
  - (C) NOMBRE DE BRINS: simple
  - (D) CONFIGURATION: linéaire
  - (ii) TYPE DE MOLECULE: ARNm (en ADN)

- (iii) HYPOTHETIQUE: NON
  - (xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 4:
- 25 ATGCAGTGGT CAGTGATAAT GGAATACTTG AAAGTAATCC CCTCACTCCA GGAACTAGTG 60

  CTCAGCTAGC AGAACTAATA GCCCTCACTT GGGCACTAGA ATTAGGAGAA GAAAAAAGGG 120

  CAAATATATA TACAGACTCT AAATATGCTT ACCTAGTCCT CCATGCCCAT GCAGCAATAT 180

  30

  GGAAAGAAAG GGAATTCCTA ACTTCTGAGA GAACACCTAT CAAACATCAG GAAGCCATTA 240

  GGAAATTATT ATTGGCTGTA CAGAAACCTA AAGAGGTGGC AGTCTTACAC TGCCGGGGTC 300

  35

  ATCANAAAGG AAAGGAAAGG GAAAATACTT TTGCCTGCAA CTATCCAATG GAAATTACTT 360

ANANCECTTE ATCANACETT TEACTTAGGE ATGGATAGEA CECATEANAT GGECANATEN 420 TTATTTACTG GACCAGGCCT TTTCAAAACT ATCAAGCAAA TATTCAGGGC CTGTGAATTG 480 5 TGCCAAAAA ATAATCCCCT GCCTCATCGC CAAGCTCCTT CAGGAAAACA AAAAACAGGC 540 CATTACCCTG AAAAAAACTG GCAACTGATT TTACCCACAA GCCCAAACCT CAGGGATTTC AGTATCTACT AGTCTGGGTA AATACTTTCA CGGGTTGGGC AAAGGCCTTC CCCTGTAGGA 10 CAGAAAAGGC CCAAGAGGTA ATAAAGGCAC TAGTTCATGA AATAATTCCC AGATTCGGAC 720 TTCCCCGAGG CTTACAGAGT GACAATAGCC CTGCTTTCCA GGCCACAGTA ACCCAGGGAG 780 15 TATCCCAGGC GTTAGGTATA CGATATCACT TACACTGCGC CTGAAGGCCA CAGTCCTCAG 840 GGAAGGTCGA GAAAATGAAT GAAATACTCA AAGGACATCT AAAAAAGCAA ACCCAGGAAA 900 CCCACCTCAC ATGGCCTGCT CTGTTGCCTA TAGCCTTAAA AAGAATCTGC AACTTTCCCC 960 20 ANANAGCAGG ACTTAGCCCA TACGANATGC TGTATGGANG GCCCTTCATA ACCANTGACC 1020 TTGTGCTTGA CCCAAGACAG CCAACTTAGT TGCAGACATC ACCTCCTTAG CCAAATATCA 1080 25 ACAAGTTCTT AAAACATTAC AAGGAACCTA TCCCTGAGAA GAGGGAAAAG AACTATTCCA 1140 CCCTTGTGAC ATGGTATTAG TCAAGTCCCT TCTCTCTAAT TCCCCATCCC TAGATACATC 1200 CTGGGAAGGA CCCTACCCAG TCATTTATT TACCCCAACT GCGGTTAAAG TGGCTGGAGT 1260 30 GGTCTTGGAT ACATCACACT TGAGTCAAAT CCTGGATACT GCCAAAGGAA CCTGAAAATC 1320 CAGGAGACAA CGCTAGCTAT TCCTGTGAAC CTCTAGAGGA TTTGCGCCTG CTCTTCAAAC 1380 35 AACAACCAGG AGGAAAGTAA CTAAAATCAT AAATCCCCCA TGGCCCTCCC TTATCATATT 1440

ATGCCCCCT CGTATAGGAG TCTTCTAAG GGAACCCCA CCTCACTGC CGGAAATATT 1560

5 GATGCCCCAT CGTATAGGAG TCTTCTAAG GGAACCCCA CCTTCACTGC CCACACCCAT 1620

ATGCCCCGCA ACTGCTATCA CTCTGCCACT CTTTGCATGC ATGCAAATAC TCATTATTGG 1680

ACAGGAAAAA TGATTAATCC TAGTTGTCCT GGAGGACTTG GAGTCACTGT CTGTTGGACT 1740

TACTTCACCC AAACTGGTAT GTCTGATGGG GGTGGAGTTC AAGATCAGGC AAGAGAAAAA 1800

CATGTAAAAG AAGTAATCTC CCAACTCACC CGGGTACATG GCACCTCTAG CCCTACAAAG 1860

15 GACTAGATCT CTCAAAACTA CATGAAACCC TCCGTACCCA TACTCGCCTG GTAAGCCTAT 1920

TTAATACCAC CCTCACTGGG CTCCATGAGG TCTCGGCCCA AAACCCTACT AACTGTTGGA 1980

TATGCCTCCC CCTGAACTTC AAGCCA 2006

(2) INFORMATIONS POUR LA SEQ ID NO: 5:

- (i) CARACTERISTIQUES DE LA SEQUENCE:
- 25 (A) LONGUEUR: 1948 paires de bases
  - (B) TYPE: nucléotide
  - (C) NOMBRE DE BRINS: simple
  - (D) CONFIGURATION: linéaire
- 30 (ii) TYPE DE MOLECULE: ARNm (en ADN)
  - (iii) HYPOTHETIQUE: NON

35

(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 5:

ACTGCACTCT TCTGGTCCAT GTTTCTTACG GCTCGAGCTG AGCTTTTGCT CACCGTCCAC

CACTGCTGTT TGCCACCACC GCANACCTGC CGCTGACTCC CATCCCTCTG GATCCTGCAG 120 GGTGTCCGCT GTGCTCCTGA TCCAGCGAGG CGCCCATTGC CGCTCCCAAT TGGGCTAAAG 180 5 GCTTGCCATT GTNCCTGCAC GGCTAAGTGC CTGGGTTTGT TCTAATTGAG CTGAACACTA 240 NTCACTGGGT TCCATGGTTC TCTTCTGTGA CCCACGGCTT CTAATAGAAC TATAACACTT 300 ACCACATGGC CCAAGATTCC ATTCCTTGGA ATCCGTGAGG GCAAGAACTC CAGGTCAGAG 360 10 ANTACGAGGC TTGCCACCAT CTTGGAAGCG GCCTGCTACC ATCTTGGAAG TGGTTCACCA 420 CCATCTTGGG AGCTCTGTGA GCAAGGACCC CCCGGTAACA TTTTGGCAAC CACGAACGGA 15 CATCCAAAGT GATACATCCT GGGAAGGACC CTACCCAGTC ATTTTATCTA CCCCAACTGC 540 GGTTAAAGTG GCTGGAGTGG AGTCTTGGAT ACATCACACT TGAGTCAAAT CCTGGATACT 600 20 GCCAAAGGAA CCTGAAAATC CAGGAGACAA CGCTAGCTAT TCCTGTGAAC CTCTAGAGGA 660 TTTGCGCCTG CTCTTCAAAC AACAACCAGG AGGAAAGTAA CTAAAATCAT AAATCCCCAT 720 GGCCCTCCCT TATCATATTT TTCTCTTTAC TGTTGTTTCA CCCTCTTTCA CTCTCACTGC 780 25 ACCCCCTCCA TGCCGCTGTA TGACCAGTAG CTCCCCTTAC CAAGAGTTTC TATGGAGAAT 840 GCAGCGTCCC GGAAATATTG ATGCCCCATC GTATAGGAGT CTTTGTAAGG GAACCCCCAC 900 30 CTTCACTGCC CACACCCATA TGCCCCGCAA CTGCTATCAC TCTGCCACTC TTTGCATGCA 960 TGCAAATACT CATTATTGGA CAGGAAAAAT GATTAATCCT AGTTGTCCTG GAGGACTTGG 1020 AGTCACTGTC TGTTGGACTT ACTTCACCCA AACTGGTATG TCTGATGGGG GTGGAGTTCA 1080 35 AGATCAGGCA AGAGAAAAAC ATGTAAAAGA AGTAATCTCC CAACTCACCC GGGTACATGG 1140

CACCTCTAGC CCCTACAAAG GACTAGATCT CTCAAAACTA CATGAAACCC TCCGTACCCA 1200 TACTCGCCTG GTAAGCCTAT TTAATACCAC CCTCACTGGG CTCCATGAGG TCTCGGCCCA 1260 5 AAACCCTACT AACTGTTGGA TATGCCTCCC CCTGAACTTC AGGCCATATG TTTCAATCCC 1320 TGTACCTGAA CAATGGAACA ACTTCAGCAC AGAAATAAAC ACCACTTCCG TTTTAGTAGG 1380 10 ACCTCTTGTT TCCAATCTGG AAATAACCCA TACCTCAAAC CTCACCTGTG TAAAATTTAG 1440 CAATACTACA TACACAACCA ACTCCCAATG CATCAGGTGG GTAACTCCTC CCACACAAAT 1500 AGTCTGCCTA CCCTCAGGAA TATTTTTTGT CTGTGGTACC TCAGCCTATC GTTGTTTGAA 1560 15 TGGCTCTTCA GAATCTATGT GCTTCCTCTC ATTCTTAGTG CCCCCTATGG CCATCTACAC 1620 TGAACAAGAT TTATACAGTT ATGTCATATC TAAGCCCCGC AACAAAAGAG TACCCATTCT 1680 20 TCCTTTGTT ATAGGAGCAG GAGTGCTAGG TGCACTAGGT ACTGGCATTG GCGGTATCAC 1740 AACCTCTACT CAGTTCTACT ACAAACTATC TCAAGAACTA AATGGGGACA TGGAACGGGT 1800 CGCCGACTCC CTGGTCACCT TGCAAGATCA ACTTAACTCC CTAGCAGCAG TAGTCCTTCA 1860 25 AAATCGAAGA GCTTTAGACT TGCTAACCGC TGAAAGAGGG GGAACCTGTT TATTTTTAGG 1920 GGAAGAATGC TGTTATTATG TTAATCAA 1948

30

35

- (2) INFORMATIONS POUR LA SEQ ID NO: 6:
  - (i) CARACTERISTIQUES DE LA SEQUENCE:
    - (A) LONGUEUR: 1136 paires de bases
    - (B) TYPE: nucléotide
    - (C) NOMBRE DE BRINS: simple

#### (D) CONFIGURATION: linéaire

- (ii) TYPE DE MOLECULE: ARNm (en ADN)
- 5 (iii) HYPOTHETIQUE: NON
  - (xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 6:

CCATGGCCAT CTACACTGAA CAAGATTTAT ACAGTTATGT CATATCTAAG CCCCGCAACA 10 AAAGAGTACC CATTCTTCCT TTTGTTATAG GAGCAGGAGT GCTAGGTGCA CTAGGTACTG 120 GCATTGGCGG TATCACAACC TCTACTCAGT TCTACTACAA ACTATCTCAA GAACTAAATG 180 GGGACATGGA ACGGGTCGCC GACTCCCTGG TCACCTTGCA AGATCAACTT AACTCCCTAG 240 CAGCAGTAGT CCTTCAAAAT CGAAGAGCTT TAGACTCGCT AACCGCTGAA AGAGGGGGAA 300 CCTGTTTATT TTTAGGGGAA GAATGCTGTT ATTATGTTAA TCAATCCGGA ATCGTCACTG 360 20 AGAAAGTTAA AGAAATTCGA GATCGAATAC AACGTAGAGC AGAAGAGCTT CGAAACACTG 420 GACCCTGGGG CCTCCTCAGC CAATGGATGC CCTGGATTCT CCCCTTCTTA GGACCTCTAG 480 CAGCTATAAT ATTGCTACTC CTCTTTGGAC CCTGTATCTT TAACCTCCTT GTTAACTTTG 540 25 TCTCTTCCAG AATCGAAGCT GTAAAACTAC AAATGGAGCC CAAGATGCAG TCCAAGACTA 600 AGATCTACCG CAGACCCCTG GACCGCCTG CTAGCCCACG ATCTGATGTT AATGACATCA 660 30 AAGGCACCC TCCTGAGGAA ATCTCAGCTG CACAACCTCT ACTACGCCCC AATTCAGCAG 720 GAAGCAGTTA GAGCGGTCGT CGGCCAACCT CCCCAACAGC ACTTAGGTTT TCCTGTTGAG 780 35 ATGGGGGACT GAGAGACAGG ACTAGCTGGA TT2000 2007 2GACTA AA TOCU AGCC 840

#### FEUILLE DE REMPLACEME

	TAGCTGGGAA GGTGACCACA TCCACCTTTA AACACGGGGC TTGCAACTTA GTTCACACCT	900
	GACCAATCAG AGAGCTCACT AAAATGCTAA TTAGGCAAAG ACAGGAGGTA AAGAAATAGC	960
5	CAATCATCTA TTGCATGAGA GCACAGCAGG AGGGACAATG ATCGGGATAT AAACCCAAGT 1	020
	CTTCGAGCCG GCAACGGCAA CCCCCTTTGG GTCCCCTCCC TTTGTATGGG AGCTCTGTTT 1	080
10	TCATGCTATT TCACTCTATT AAATCTTGCA GCTGCGAAAA AAAAAAAAAA	136
10		
	(2) INFORMATIONS POUR LA SEQ ID NO: 7:	٠,
	(i) CARACTERISTIQUES DE LA SEQUENCE:	
15	(A) LONGUEUR: 2782 paires de bases	
	(B) TYPE: nucléotide	
	(C) NOMBRE DE BRINS: simple	
	(D) CONFIGURATION: linéaire	
20	(ii) TYPE DE MOLECULE: ARNm (en ADN)	
	(iii) HYPOTHETIQUE: NON	
25	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 7	
	ATGGGAGCTG TTTTCATGCT ATTTCACTCT ATTTCATCTT GCAACTGCAC TCTTCTGGTC	60
	CATGITICIT ACGCCTCGAG CTGAGCTTTT GCTCACCGTC CACGAGTCGT GTTTT	

ACCGCAGACC TGCCGCTGAC TCCCATCCCT CTGGATCCTG CACCACTGCT GTTTGCCACC 120

ACCGCAGACC TGCCGCTGAC TCCCATCCCT CTGGATCCTG CAGGGTGTCC GCTGTGCTCC 180

TGATCCAGCG AAGCGCCCAT TGCCGCTCCC AATTGGGCTA AAGGCTTGCC ATTGTTCCTG 240

CACGGCTAAG TGCCTGGGTT TGTTCTAATT GAGCTGAACA CTAGTCACTG GGTTCCATGG 300

35

TTCTCTTCTG TGACCCACGG CTTCTAATAG AACTATAACA CTTACCACAT GGCCCAAGAT 360

**FEUILLE DE REMPLACEMENT (REGLE 26)** 

1. 2.

TCCATTCCTT GGAATCCGTG AGGCCAACGA ACTCCAGGTC AGAGAATACG AAGCTTGCCA CCATCTTGGA AGCGGCCTGC TACCATCTTG GAAGTGGTTC ACCACCATCT TGGGAGCTCT 5 GTGAGCAAGG ACCCCCGGT GACATTTTGG CGACCACCAA CGGACATCCC AAGTGATACA TCCTGGGAAG GACCCTACCC AGTCATTTTA TCTACCCCAA CTGCGGTTAA AGTGGCTGGA 600 10 GTGGAGTCTT GGATACATCA CACTTGAGTC AAATCCTGGA TACTGCCAAA GGAACCTGAA 660 AATCCAGGAG ACAACGCTAG CTATTCCTGT GAACCTCTAG AGGATTTGCG CCTGCTCTTC 720 AAACAACAAC CAGGAGGAAA GTAACTAAAA TCATAAATCC CCATGGGCCT CCCTTATCAT 780 15 ATTTTTCTCT GTAGTGTTCT TTCACCCTGT TTCACTCTCA CTGCACCCCC TCCATGCCGC 840 TGTATGACCA GTAGCTCCCC TCACCCAGAG TTTCTATGGA GAATGCAGCG TCCCGGAAAT 900 20 ATTGATGCCC CATCGTATAG GAGTCTTTCT AAGGGAACCC CCACCTTCAC TGCCCACACC 960 CATATGCCCC GCAACTGCTA TCACTCTGCC ACTCTTTGCA TGCATGCAAA TACTCATTAT 1020 TGGACAGGAA AAATGATTAA TCCTAGTTGT CCTGGAGGAC TTGGAGTCAC TGTCTGTTGG 1080 25 ACTTACTTCA CCCAAACTGG TATGTCTGAT GGGGGTGGAG TTCAAGATCA GGCAAGAGAA 1140 AAACATGTAA AAGAAGTAAT CTCCCAACTC ACCGGGGTAC ATGGCACCTC TAGCCCCTAC 1200 30 AAAGGACTAG ATCTCTCAAA ACTACATGAA ACCCTCCGTA CCCATACTCG CCTGGTAAGC 1260 CTATTTAATA CCACCCTCAC TGGGCTCCAT GAGGTCTCGG CCCAAAACCC TACTAACTGT 1320 TGGATATGCC TCCCCTGAA CTTCAGGCCA TATGTTTCAA TCCCTGTACC TGAACAATGG 1380 35 AACAACTTCA GCACAGAAAT AAACACCACT TCCGTTTTAG TAGGACCTCT TGTTTCCAAT 1440

GTGGAAATAA CCCATACCTC AAACCTCACC TGTGTAAAAT TTAGCAATAC TACATACACA 1500 ACCAACTCCC AATGCATCAG GTGGGTAACT CCTCCCACAC AAATAGTCTG CCTACCCTCA 1560 5 GGAATATTTT TTGTCTGTGG TACCTCAGCC TATCGTTGTT TGAATGGCTC TTCAGAATCT 1620 ATGTGCTTCC TCTCATTCTT AGTGCCCCCT ATGACCATCT ACACTGAACA AGATTTATAC 1680 10 AGTTATGTCA TATCTAAGCC CCGCAACAAA AGAGTACCCA TTCTTCCTTT TGTTATAGGA 1740 GCAGGAGTGC TAGGTGCACT AGGTACTGGC ATTGGCGGTA TCACAACCTC TACTCAGTTC 1800 TACTACAAAC TATCTCAAGA ACTAAATGGG GACATGGAAC GGGTCGCCGA CTCCCTGGTC 1860 15 ACCTTGCAAG ATCAACTTAA CTCCCTAGCA GCAGTAGTCC TTCGAAATCG AAGAGCTTTA 1920 GACTTGCTAA CCGCTGAGAG AGGGGGAACC TGTTTATTTT TAGGGGAAGA ATGCTGTTAT 1980 20 TATGTTAATC AATCCGGAAT CGTCACTGAG AAAGTTGAAG AAATTCCAGA TCGAATACAA 2040 CGTATAGCAG AGGAGCTTCG AAACACTGGA CCCTGGGGCC TCCTCAGCCG ATGGATGCCC 2100 TGGATTCTCC CCTTCTTAGG ACCTCTAGCA GCTATAATAT TGCTACTCCT CTTTGGACCC 2160 25 TGTATCTTTG ACCTCCTTGT TAACTTTGTC TCTTCCAGAA TCGAAGCTGT GAAACTACAA 2220 ATGGAGCCCA AGATGCAGTC CAAGACTAAG ATCTACCGCA GACCCCTGGA CCGGCCTGCT 2280 AGCCCATGAT CTGATGTTAA TGACATCAAA GGCACCCCTC CTGAT CTCAGCTGCA 2340 30 CAACCTCTAC TAUGCCCCAA TTCAGCAGGA AGCAGTTAGA GCGGTGGTCG GCCAACCTCC 2400 ATT 2460 CONACAGOAC TINGCITTIC CIGITY OF CO 35 AL. AGAA' AAGCCTA GGTGC NAGG TGACCACATC CACCTTMAAA 2520 TCC1

7 F

	CACGGGGCTT	GCAACTTAGC	TCACACCTGA	CCAATCAGAG	AGCTCACTAA	AATGCTAATT	2580
5	AGGCAAAGAC	AGGAGGTAAA	GAAATAGCCA	ATCATTTATT	GCCTGAGAGC	ACAGCAGGAG	2640
J	GGACAATGAT	CGGGATATAA	ACCCAAGTTT	TCGAGCCGGC	AACGGCAACC	CCCTTTGGGT	2700
	CCCCTCCCTT	TGTATGGGAG	CTCTGTTTTC	ATGCTATTTC	ACTCTATTAA	ATCTTGCAAC	2760
10	TGCAAAAAAA	ААААААААА	AA				2782

- (2) INFORMATIONS POUR LA SEQ ID NO: 8:
- 15 (i) CARACTERISTIQUES DE LA SEQUENCE:
  - (A) LONGUEUR: 666 paires de bases
  - (B) TYPE: nucléotide
  - (C) NOMBRE DE BRINS: simple
  - (D) CONFIGURATION: linéaire

20

- (ii) TYPE DE MOLECULE: ARNm (en ADN)
- (iii) HYPOTHETIQUE: NON
- 25 (xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 8:

TGTCCGCTGT GCTCCTGATC CAGCGAGGCG CCCATTGCCG CTCCCAATTG GGCTAAAGGC 60

TTGCCATTGT TCCTGCACGG CTAAGTGCCT GGGTTTGTTC TAATTGAGCT GAACACTANT 120

30

CACTGGGTTC CATGGTTCTC TTCTGTGACC CACGGCTTCT AATATAACTA TAACACTTAC 180

CACATGGCCC AAGATTCCAT TCCTTGGAAT CCGTGAGGCC AAGAACTCCA GGTCAGAGAA 240

35 TACGAGGCTT GCCACCATCT TGGAAGCGGC CTGCTACCAT CTTGGAAGTG GTTCACCACC 300

	ATCTTGGGAG CTCTGTGAGC AAGGACCCCC CGGTAACATT TTGGCAACCA CGAACGGACA	360
	TCCAAAGTGA ATCGAAGCTG TAAAACTACA AATGGAGCCC AAGATGCAGT CCAAGACTAA	420
5	GATCTACCGC AGACCCCTGG ACCGGCCTGC TAGCCCACGA TCTGATGTTA ATGACATCAA	480
	AGGCACCCCT CCTGAGGAAA TCTCAGCTGC ACAACCTCTA CTACGCCCCA ATTCAGCAGG	540
10	AAGCAGTTAG AGCGGTCGTC GGCCAACCTC CCCAACAGCA CTTAGGTTTT CCTGTTGAGA	600
	TGGGGGACTG AGAGACAGGA CTAGCTGGAT TTCCTAGGCT GACTAAGAAT CCCTAAGCCT	660
	AGCTGG	666
15	(2) INFORMATIONS POUR LA SEQ ID NO: 9:	
20	<ul> <li>(i) CARACTERISTIQUES DE LA SEQUENCE:</li> <li>(A) LONGUEUR: 3372 paires de bases</li> <li>(B) TYPE: nucléotide</li> <li>(C) NOMBRE DE BRINS: simple</li> </ul>	
	(D) CONFIGURATION: linéaire	
25	(ii) TYPE DE MOLECULE: ARNm (en ADN)  (iii) HYPOTHETIQUE: NON	
	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 9:	
30	GACTTCCCAA ATACCAGAGG AAGCAGAGTG GTTTACAGTC CTGGACCTTC AGGATGCCTT	60
	CTTCTGCATC CCTGTACATC CTGACTCTCA ATTCTTGTTT GCCTTTGAAG ATACTTCAAA	120
35	CCCAGCATCT CAACTCACCT GGACTATTTT ACCCCAAGGG TTCAGGGATA GTCCCCATCT	180
	ATTTGGCCAG GCATTAGCCC AAGACTTGAG CCAATCCTCA TACCTGGACA CTTCTCCTTC	240

GGTAGGTGGA TGATTTACTT TTGGCCGCCC ATTCAGAAAC CTTGTGCCAT CAAGCCACCC 300 AAGCGCTCTT CAATTTCCTC GCTACCTGTG GCTACATGGT TTCCAAACCA AAGGCTCAAC 360 5 TCTGCTCACA GCAGGTTACT TAGGGCTAAA ATTATCCAAA GGCACCAGGG CCCTCAGTGA 420 GGAACACATC CAGCCTATAC TGGCTTATCC TCATCCCAAA ACCCTAAAGC AACTAAGGGG 10 ATTCCTTGGC GTAATAGGTT TCTGCCGAAA ATGGATTCCC AGGTATGGCG AAATAGCCAG 540 GTCATTAAAT ACACTAATTA AGGAAACTCA GAAAGCCAAT ACCCATTTAG TAAGATGGAC 600 AACTGAAGTA GAAGTGGCTT TCCAGGCCCT AACCCAAGCC CCAGTGTTAA GTTTGCCAAC 660 15 AGGGCAAGAC TTTTGTTCAT ATGTCACAGA AAAAACAGGA ATAGCTCTAG GAGTCCTTAC 720 ACAGATCCGA GGGATGAGCT TGCAACCTGT GGCACACCTG ACTAAGGAAA TTGATGTAGT 780 20 GGCAAAGGGT TGACCTCATT GTTTACGGGT AGTGGTGGCA GTAGCAGTCT TAGTATCTGA 840 AGCAGTTAAA ATAATACAGG GAAGAGATCT TACTGTGTGG ACATCTCATG ATGTGAATGG 900 CATACTCACT GCTAAAGGAG ACTTGTGGCT GTCAGACAAC TGTTTACTTA AATGTCAGGC 960 25 TCTATTACTT GAAGGGCCAG TGCTGCGACT GTGCACTTGT GCAACTCTTA ACCCAGCCAC 1020 ATTTCTTCCA GACAATGAAG AAAAGATAAA ACATAACTGT CAACAAGTAA TTTCTCAAAC 1080 CTATGCCACT CGAGGGGACC TTTTAGAGGT TCCTTTGACT GATCCCGACC TCAACTTGTA 1140 TACTGATGGA AGTTCCTTTG TAGAAAAAGG ACTTCGAAAA GTGGGGTATG CAGTGGTCAG 1200 TGATAATGGA ATACTTGAAA GTAATCCCCT CACTCCAGGA ACTAGTGCTC AGCTAGCAGA 1260 35 ACTANTAGCC CTCACTTGGG CACTAGAATT AGGAGAAGAA AAAAGGGCAA ATATAATACA 1320

GACTCTAAAT ATGCTTACCT AGTCCTCCAT GCCCATGCAG CAATATGGAA AGAAAGGGAA 1380 TTCCTAACTT CTGAGAGAAC ACCTATCAAA CATCAGGAAG CCATTAGGAA ATTATTATTG 1440 5 GCTGTACAGA AACCTAGAGA GGTGGCAGTC TTACACTGCC GGGGTCATCA CAAAGGAAAG 1500 GAAAGGGAAA TACAAGAGAA CTGCCAAGCA TATATTGAAG CCAAAAGAGC TGCAAGGCAG 1560 10 GACCCTCCAT TAGAAATGCT TATTAAACTT CCCTTAGTAT AGGGTAATCC CTTCCGGGAA 1620 ACCAAGCCCC AGTACTCAGC AGGAGAAACA GAATGGGGAA CCTCACGAGG CAGTTTTCTC 1680 CCCTCGGGAC GGTTAGCCAC TGAAGAAGGG AAAATACTTT TGCCTGCAAC TATCCAATGG 1740 15 AAATTACTTA AAACCCTTCA TCAAACCTTT CACTTAGGCA TCGATAGCAC CCATCAGATG 1800 GCCAAATCAT TATTTACTGG ACCAGGCCTT TTCAAAACTA TCAAGCAGAT AGTCAGGGCC 1860 20 TGTGAAGTGT GCCAGAGAAA TAATCCCCTG CCTTATCGCC AAGCTCCTTC AGGAGAACAA 1920 AGAACAGGCC ATTACCCTGG AGAAGACTGG CAACTGATTT TACCCACAAG CCCAAACCTC 1980 AGGGATTTCA GTATCTACTA GTCTGGGTAG ATACTTTCAC GGGTTGGGCA GAGGCCTTCC 2040 25 CCTGTAGGAC AGAAAAGGCC CAAGAGGTAA TAAAGGCACT AGTTCATGAA ATAATTCCCA 2100 GATTCGGACT TCCCCGAGGC TTACAGAGTG ACAATAGCCC TGCTTTCCAG GCCACAGTAA 2160 30 CCCAGGGAGT ATCCCAGGCG TTAGGTATAC GATATCACTT ACACTGCGCC TGAAGGCCAC 2220 AGTCCTCAGG GAAGGTCGAG AAAATGAATG AAACACTCAA AGGACATCTA AAAAAGCAAA 2280 CCCAGGAAAC CCACCTCACA TGGCCTGTTC TGTTGCCTAT AGCCTTAAAA AGAATCTGCA 2340 35 ACTITICCCA AAAAGCAGGA CITAGCCCAT ACGAAATGCI GIAIGGAAGG CCCITCATAA 2400

CCAATGACCT TGTGCTTGAC CCAAGACAGC CAACTTAGTT GCAGACATCA CCTCCTTAGC 2460 CAAATATCAA CAAGTTCTTA AAACATTACA AGGAACCTAT CCCTGAGAAG AGGAAAAGAA 2520 5 TATTCCACCC AAGTGACATG GTATTAGTCA AGTCCCTTCC CTCTAATTCC CCATCCCTAG 2580 ATACATCCTG GGAAGGACCC TACCCAGTCA TTTTATCTAC CCCAACTGCG GTTAAAGTGG 2640 CTGGAGTGGA GTCTTGGATA CATCACACTT GAGTCAAATC CTGGATACTG CCAAAGGAAC 2700 10 CTGAAAATCC AGGAGACAAC GCTAGCTATT CCTGTGAACC TCTAGAGGAT TTGCGCCTGC 2760 TCTTCAAACA ACAACCAGGA GGAAAAATCG AAGCTGTAAA ACTACAAATG GAGCCCAAGA 2820 15 TGCAGTCCAA GACTAAGATC TACCGCAGAC CCCTGGACCG GCCTGTTAGC CCACGATCTG 2880 ATGTTAATGA CATCAAAGGC ACCCCTCCTG AGGAAATCTC AGCTGCACAA CCTCTACTAC 2940 20 GCCCCAATTC AGCAGGAAGC AGTTAGAGCG GTCGTCGGCC AACCTCCCCA ACAGCACTTA 3000 GGTTTTCCTG TTGAGATGGG GGACTGAGAG ACAGGACTAG CTGGATTTCC TAGGCTGATT 3060 AAGAATCCCT AAGCCTAGCT GGGAAGGTGA CCACATCCAC CTTTAAACAC GGGGCTTGCA 3120 25 ACTTAGCTCA CACCTGACCA ATCAGAGAGC TCACTAAAAT GCTAATTAGG CAAAGACAGG 3180 AGGTAAAGAA ATAGCCAATC ATTTATTGCC TGAGAGCACA GCAGGAGGGA CAATGATCGG 3240 30 GATATAAACC CAAGTTTTCG AGCCGGCAAC GGCAACCCCC TTTGGGTCCC CTCCCTTTGT 3300 ATGGGAGCTC TGTTTTCATG CTATTTCACT CTATTAAATC TTGCAACTGC AAAAAAAAA 3360 AAAAAAAAA AA 3372

#### (2) INFORMATIONS POUR LA SEQ ID NO: 10:

- (i) CARACTERISTIQUES DE LA SEQUENCE:
  - (A) LONGUEUR: 2372 paires de bases
  - (B) TYPE: nucléotide
  - (C) NOMBRE DE BRINS: simple
  - (D) CONFIGURATION: linéaire
- (ii) TYPE DE MOLECULE: ARNm (en ADN)

10

- (iii) HYPOTHETIQUE: NON
- (xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 10:
- ACTGCACTCT TCTGGTCCAT GTTTCTTACG GCTCGAGCTG AGCTTTTGCT CACCGTCCAC CACTGCTGTT TGCCACCACC GCAGACCTGC CGCTGACTCC CATCCCTCTG GATCCTGCAG GGTGTCCGCT GTGCTCCTGA TCCAGCGAGG CGCCCATTGC CGCTCCCAAT TGGGCTAAAG 20 GCTTGCCATT GTTCCTGCAC GGCTAAGTGC CTGGGTTTGT TCTAATTGAG CTGAACACTA ATCACTGGGT TCCATGGTTC TCTTCTGTGA CCCACGGCTT CTAATAGAAC TATAACACTT 300 25 ACCACATGGC CCAAGATTCC ATTCCTTGGA ATCCGTGAGG CCAAGAACTC CAGGTCAGAG 360 AATACGAGGC TTGCCACCAT CTTGGAAGCG GCCTGCTACC GTCTTGGAAG TGGTTCACCA CCATCTTGGG AGCTCTGTGA GCAAGGACCC CCCGGTAACA TTTTGGCAAC CAACGACGGA 30 CATCCAAAGT GATGGGAAAC GTTCCCCGCA AGACAAAAAC GCCCCTAAGA CGTATTCTGG AGAATTGGGA CCAATTTGAC CCTCAGACAC TAAGAAAGAA ACGACTTATA TTCTTCTGCA 600 35 GTGCCGCCTG GCACTCCTGA GGGAAGTATA AATTATAACA CCATCTTACA GCTAGACCTC 660

TTTTGTAGAA AAGGCAAATG GAGTGAAGTG CCATAAGTAC AAACTTTCTT TTCATTAAGA GACAACTCAC AATTATGTAA AAAGTGTGAT TTATGCCCTA CAGGAAGCCT TCAGAGTCTA 780 5 CCTCCCTATC CCAGCATCCC CGACTCCTTC CCCAACTAAT AAGGACCCCC CTTCAACCCA 840 AATGGTCCAA AAGGAGATAG ACAAAAGGGT AAACAGTGAA CCAAAGAGTG CCAATATTCC CCAATTATGA CCCCTCCAAG CAGTGGGAGG AAGAGAATTC GGCCCAGCCA GAGTGCATGT 960 10 GCCTTTTTCT CTCCCAGACT TAAAGCAAAT AAAAACAGAC TTAGGTAAAT TCTCAGATAA 1020 CCCTGATGGC TATATTGATG TTTTACAAGG GTTAGGACAA TTCTTTGATC TGACATGGAG 1080 15 AGATATAATG TCACTGCTAA ATCAGACACT AACCCCAAAT GAGAGAAGTG CCACCATAAC 1140 TGCAGCCTGA GGGTTTGGCG TCTCTGGTAT CTCAGTCAGG TCAATGGATA NGGATGACAA 1200 CAGAAGGAAA GANAATGATT CCCCACAGGC CAGCAGGCAG TTCCCAGTCT AGACCCTCAT 1260 20 TGGGACACAG AATCAGAACA TGGAGATTGG TGCTGCAGAC ATTTGCTAAC TTGTGTGCTA 1320 GAAGGACTAA GGAAAACTAG GAAGAAGTCT ATGAATTACT CAATGATGTC CACCATAACA 1380 25 CAGGGAAGGG AAGAAAATCC TACTGCCTTT CTGGAGAGAC TAAGGGAGGC ATTGAGGAAG 1440 CGTGCCTCTC TGTCACCTGA CTCTTCTGAA GGCCAACTAA TCTTAAAGCG TAAGTTTATC 1500 ACTCAGTCAG CTGCAGACAT TAGAAAAAAC TTCAAAAGTC TGCCGTAGGC CCGGAGCAAA 1560 30 ACTTAGAAAC CCTATTGAAC TTGGCAACCT CGGTTTTTTA TAATAGAGAT CAGGAGGAGC 1620 AGGCGGAACA GGACAAACGG GATTAAAAAA AAGGCCACCG CTTTAGTCAT GACCCTCAGG 1680 35 CAAGTGGACT TTGGAGGCTC TGGAAAAGGG AAAAGCTGGG CAAATTGAAT GCCTAATAGG 1740

GCTTGCTTCC AGTGCGGTCT ACAAGGACAC TTTAAAAAAG ATTGTCCAAG TAGAAGTAAG 1800

CCGCCCCTTC GTCCATGCCC CTTATTTCAA GGGAATCACT GGAAGGCCCA CTGCCCCAGG 1860

GGACAAAGGT CTTTTGAGTC AGAAGCCACT AACCAGATGA TCCAGCAGCA GGACTGAGGG 1920

TGCCTGGGGC AAGCGCCATC CCATGCCATC ACCCTCACAG AGCCCTGGGT ATGCTTGACC 1980

ATTGAGGGCC AGGAAGGTTG TCTCCTGGAC ACTGGTGCGG TCTTCTTAGT CTTACTCTTC 2040

TGTCCCGGAC AACTGTCCTC CAGATCTGTC ACTATTCTGA GGGGGTCCNT AAGACGGGCA 2100

GTCACTAGAT ACTTTTCCC AGCCACTAAG TTATGAACTG GGGAGCTTTA TTCTTTTCAC 2160

AAGCAGGGGC CATTATACAC CTGAACATAG GAGAAGGAAC ACCCGTTTGT TGTNCCCCTG 2280

CTTGAGGAAG GAATTAATCC TGAAGTCTGG GCAACAGAAG GACAATATGG ACGAGCCAAA 2340

GAATGCCCGT CCTGTTCAAG TTAAACTAAA GG

(2) INFORMATIONS POUR LA SEQ ID NO: 11:

25

- (i) CARACTERISTIQUES DE LA SEQUENCE:
  - (A) LONGUEUR: 7582 paires de bases
  - (B) TYPE: nucléotide
  - (C) NOMBRE DE BRINS: simple
- 30 (D) CONFIGURATION: linéaire
  - (ii) TYPE DE MOLECULE: ARNm (en ADN)
    - (141) HYPOTH TOTAL NON

35

(X1) DESCRIPTION ... A SEQUENT . ... 2 ID NO: 11:

F UL

EMEN

	CAACAATCGG	GATATAAACC	CAGGCATTCG	AGCTGGCAAC	AGCAGCCCC	CTTTGGGTC	. 60
	CTTCCCTTTG	TATGGGAGCT	GTTTTCATGC	TATTTCACTC	TATTAAATCT	TGCAACTGC	120
	CTCTTCTGGT	CCATGTTTCT	TACGGCTCGA	GCTGAGCTTT	TGCTCACCGT	CCACCACTG	180
5	TGTTTGCCAC	CACCGCANAC	CTGCCGCTGA	CTCCCATCCC	TCTGGATCCT	GCAGGGTGT	240
	CGCTGTGCTC	CTGATCCAGO	GARGCGCCCA	TTGCCGCTCC	CAATTGGGCT	AAAGGCTTGC	300
	CATTGTNCCT	GCACGGCTAA	GTGCCTGGGT	TTGTTCTAAT	TGAGCTGAAC	ACTANTCACT	360
	GGGTTCCATG	GTTCTCTTCT	GTGACCCACG	GCTTCTAATA	KAACTATAAC	ACTTACCACA	420
	TGGCCCAAGA	TTCCATTCCT	TGGAATCCGT	GAGGSCAACG	AACTCCAGGT	CAGAGAATAC	480
10	GARGCTTGCC	ACCATCTTGG	AAGCGGCCTG	CTACCRTCTT	GGAAGTGGTT	CACCACCATO	540
	TTGGGAGCTC	TGTGAGCAAG	GACCCCCGG	TRACATTTTG	GCRACCAMSR	ACGGACATCO	600
	MAAGTGATGG	GAAACGTTCC	CCGCAAGACA	AAAACGCCCC	TAAGACGTAT	TCTGGARAAT	660
	TGGGAMCAAT	TTGACCCTCA	GACACTAAGA	AAGAAACGAC	TTATATTCTT	CTGCAGTGCC	720
	GCCTGGCACT	CCTGAGGGAA	GTATAAATTA	TAACACCATC	TTACAGCTAG	ACYTCTTTTG	780
15	TAGAAAAGGC	AAATGGAGTG	AAGTGCCATA	AGTACAAACT	TTCTTTTCAT	TAAGAGACAA	840
	CTCACAATTA	TGTAAAAAGT	GTGATTTATG	CCCTACAGGA	AGCCTTCAGA	GTCTACCTCC	900
	CTATCCCAGC	ATCCCCGACT	CCTTCCCCAM	YTAATAAGGA	CCCCCTTCA	ACCCAAATGG	960
	TCCAAAAGGA	GATAGACAAA	AGGGTAAACA	GTGAACCAAA	GAGTGCCAAT	ATTCCCCAAT	1020
	TATGACCCCT	CCCAAGCAGT	GGGAGGAAGA	GAATTCGGCC	CAGCCAGAGT	GCATGTGCYT	1080
20	TTTYYTCTCC	CAGACTTAAA	GCAAATAAAA	ACAGACTTAG	GTAAATTCTC	AGATAAYCCT	1140
	GATGGCTATA	TTGRTGTTTT	ACAAGGGTTA	GGACAATTCT	TTGATCTGAC	ATGGAGAGAT	1200
	ATATATGTCA	CTGCTAAATC	AGACACTAAC	CCCAAATGAG	AGAAGTGCCA	CCATAACTGC	1260
	AGCCTGAGRG	TTTGGCGATC	TCTGGTATCT	CAGTCAGGTC	AATGGATANG	GATGACAACA	1320
	GAAGGAAAGA	NAATGATTCC	CCACAGGCCA	GCARGCAGTT	CCCAGTCTAS	ACCCTCATTG	1380
25	GGGACACAGA	AATCAGTAAC	ATGGGAGATT	GGTGCTGCAG	ACATTTGCTA	ACTTGTGTGC	1440
	TASAAGGACT	AAGGAAAACT	ASGAAGAAAR	TCTAYGAATT	ACTCAATGAT	GTCCACCATA	1500
	ACACAGGGGA	AGGGAAGAAA	ATCCTACTGC	CTTTCTGGAG	AGACTAAGGG	AGGCATTGAG	1560
	GAAGCGTGCC	TCTCTGTCAC	CTGACTCTTC	TGAAGGCCAA	CTAATCTTAA	AGCGTAAGTT	1620
u."	TATCACTCAG	TCAGCTGCAG	ACATTAGAAA	AAACTTCAAA	AGTCTGCCGT	AGGCCCGGAG	1680
30	CAAAACTTAG	AAACCCTATT	GAACTTGGCA	ACYTCGGTTT	TTTATAATAG	AGATCAGGAG	1740
	GAGCAGGCGG	AACAGGACAA	ACGGGATTAA	AAAAAAGGCC	ACCGCTTTAG	TCATGACCCT	1800
	CAGGCAAGTG	GACTTTGGAG	GCTCTGGAAA	AGGGAAAAGC	TGGGCAAATT	GAATGCCTAA	1860
			GTCTACAAGG				
	TAAGCCGCCC	CTTCGTCCAT	GCCCCTTATT	TCAAGC	רמגמד	3000°	1980
35	CAGGGGACAA	AGGTCTTTTG	<b>AGTCAGA</b> F	~ ~ <b>~</b> ~ ~	ardar od	AGC. CTG	2040
	AGGGTGCCTG	GGGCAAGCGC	CATCC	JCC"	JAGREGOOF	GGGTATGCTT	2100

GACCATTGAG GGCCAGGAAG GTTGTCTCCT GGACACTGGT GCGGTCTTCT TAGTCTTACT 2160 CTTCTGTCCC GGACACTGT CCTCCAGATC TGTCACTATT CTGAGGGGGT CCNTAAGACG 2220 GGCAGTCACT AGATACTTTY TCCCAGCCAC TAAGTTATGA ACTGGGGAGC TTTATTCTTT 2280 TCACATGCTT TTCTAATTAT GCTTGAAAGC CCCACTACCT TGTTAGGGAG AGACATTCTA 2340 5 GCAAAGCAG GGGCCATTAT ACACCTGAAC ATAGGAGAAG GAACACCCGT TTGTTGTNCC 2400 CCTGCTTGAG GAAGGAATTA ATCCTGAAGT CTGGGCAACA GAAGGACAAT ATGGACGAGC 2460 CAAAGAATGC CCGTCCTGTT CAAGTTAAAC TAAAGGATTC CACTTCCTTT CCCTACCAAA 2520 GGCAGTACCC CCTCAGACCC AAGGCCCAAC AAGGATTCCA AAAGATTGTT AAGGACTTAA 2580 AAGCCCAAGG CTTAGTAAAA CCATGCATAA CTCCCTGCAG TAATTCCGTA GTGGATTGAG 2640 10 GAGGCACAGA AACCCAGTGG ACAGTGGAGG GTTAGTGCAA GATCTCAGGA TTATCAATGG 2700 AGGCCGTTGT CCTTTTATAC CCAGCTGTAC CTAGCCCTTA TACTGTGMYT TCCCAAATAC 2760 CAGAGGAAGC AGAGTGGTTT ACASTCCTGG ACCTTMAGGA TGCCTTCTTC TGCATCCCTG 2820 TACATCCTGA CTCTCAATTC TTGTTTGCCT TTGAAGATAC TTCAAACCCA RCATCTCAAC 2880 TCACCTGGAC TRTTTTACCC CAAGGGTTCA GGGATAGYCC CCATCTATTT GGCCAGGCAT 2940 15 TAGCCCAAGA CTTGAGYCAR TYMTCATACC TGGACACTCT TGTCCTTCRG TAKGTGGATG 3000 ATTTACTTTT RGCYGCCYRT TCAGAAACCT TGTGCCATCA AGCCACCCAA GCRCTCTTMA 3060 ATTTCCTCGC YACCTGTGGC TACAWGGTTT CCAAACSARA RGCTCARCTC TGCTCACAGC 3120 AGGTTAAATA CTTAGGRCTA ARATTATCCA AAGGCACCAR GGCCCTCAGT GAGGAAYRYA 3180 TCCAGCCTAT ACTGGCTTAT CCTCATCYCA AAACCCTAAA GCAACTAAGR GRRTTCCTTG 3240 20 GCRTAAYAGG YTTCTGCCGA AWATGGATTC CCCAGGTWTG GCRAAATAGC CAGGYCATTA 3300 WATACASTAA TTAAGGAAAC TCAGAAAGCC AATACCCATT TARTAAGATG GAYAMCTGAA 3360 GYMRAAGTGG CTTTCCAGGC CCCTAAAGAA GGCCTTAAAC CCAAGYCCCA GTGTTAAGYT 3420 TGCCAACRGG GCAAGACTTT TSTTYATAYR TCACAGAAAA AAACAGRAAY AGCTCTRGGA 3480 GTCCTTACAC AGRTCCRAGG GAYGAGCTTG CAACCYRTGG CRYACCTGAS TAAGGAAAYT 3540 25 GATGTAGTGG CAAAGGGTTG RCYTCATTGT TTAYGGGTAG TGGTGGCAGT AGCAGTYKTA 3600 GTATCTGAAG CAGTTAAAAT AATACAGGGR AGAGATCTTA CTGTGTGGAC ATCTCATGAK 3660 GTGAAYRGCA TACTCACTGC TAAAGGAGAC TTGTGGCTGT CAGACAACYG TTTACTTAAA 3720 TRTCAGGCTC TATTACTTGA ARGGCCAGTG CTGCRACTGT GCACTTGTGC AACTCTTAAC 3780 CCAGYCNCAT TTCTTCCAGA CAATGAAGAA AAGATARAAY ATAACTGTCA ACAARTAATT 3840 30 TCTCAAACCT ATGCCACTCG AGGGGACCTT YTAGARGTTC CYTTGACTGA TCCYGACCTT 3900 CAACTTGTAT ACTGATGGAA GTTCCTTTGT AGAAAAAGGA CTTCGAAAAG YGGGGTATGC 3960 AGTGGTCAGT GATAATGGAA TAYTTGAAAG TAATCCCCTC ACTCCAGGAA CTAGTGCTYA 4020 GCTRGCAGAA CTAATAGCCY TCAYTKGGGC ACTAGAATTA GGAGAAGRAA AAAGGGYAAA 4080 TATATATACA GACTCTRART ATGCTYACCT AGTCNTCC CAATATISAR 4140 35 AGAAAGGGAA TTCCTAACTT CYGAGR CATE LAAG CO **GAR 4200** ATTATTAYTG GCWGTACAGA AACCTARAG AGTC TESSACE 1 C. JGTCATCA 4260

NAAAGGAAAG RAAAGGGAAA TASAAGRGAA YTGCCAAGCA KATATTGAAG CMAAAAGAGC 4320 TGCAAGGCAG GACCCTCCAT TAGAAATGCT TATTAAACTT CCCTTAGTAT AGGGTAATCC 4380 CTTCCGGGAA ACCAAGCCCC AGTACTCAGC AGGAGAAACA GAATGGGGAA CCTCACGAGG 4440 CAGTTTTCTC CCCTCGGGAC GGTTAGCCAC TGAAGAAGGG AAAATACTTT TGCCTGCAAC 4500 TATCCAATGG AAATTACTTA AAACCCTTCA TCAAACCTTT CACTTAGGCA TCGATAGCAC 4560 CCATCARATG GCCAAATCAT TATTTACTGG ACCAGGCCTT TTCAAAACTA TCAAGCARAT 4620 AKTCAGGGCC TGTGAAKTGT GCCARARAAA TAATCCCCTG CCTYATCGCC AAGCTCCTTC 4680 AGGARAACAA ARAACAGGCC ATTACCCTGR ARAARACTGG CAACTGATTT TACCCACAAG 4740 CCCAAACCTC AGGGATTTCA GTATCTACTA GTCTGGGTAR ATACTTTCAC GGGTTGGGCA 4800 10 RAGGCCTTCC CCTGTAGGAC AGAAAAGGCC CAAGAGGTAA TAAAGGCACT AGTTCATGAA 4860 ATAATTCCCA GATTCGGACT TCCCCGAGGC TTACAGAGTG ACAATAGCCC TGCTTTCCAG 4920 GCCACAGTAA CCCAGGGAGT ATCCCAGGCG TTAGGTATAC GATATCACTT ACACTGCGCC 4980 TGAAGGCCAC AGTCCTCAGG GAAGGTCGAG AAAATGAATG AAAYACTCAA AGGACATCTA 5040 AAAAAGCAAA CCCAGGAAAC CCACCTCACA TGGCCTGYTC TGTTGCCTAT AGCCTTAAAA 5100 15 AGAATCTGCA ACTTTCCCCA AAAAGCAGGA CTTAGCCCAT ACGAAATGCT GTATGGAAGG 5160 CCCTTCATAA CCAATGACCT TGTGCTTGAC CCAAGACAGC CAACTTAGTT GCAGACATCA 5220 CCTCCTTAGC CAAATATCAA CAAGTTCTTA AAACATTACA AGGAACCTAT CCCTGAGAAG 5280 AGGGAAAAGA ACTATTCCAC CCWWGTGACA TGGTATTAGT CAAGTCCCTT CYCTCTAATT 5340 CCCCATCCCT AGATACATCC TGGGAAGGAC CCTACCCAGT CATTTTATYT ACCCCAACTG 5400 20 CGGTTAAAGT GGCTGGAGTG GAGTCTTGGA TACATCACAC TTGAGTCAAA TCCTGGATAC 5460 TGCCAAAGGA ACCTGAAAAT CCAGGAGACA ACGCTAGCTA TTCCTGTGAA CCTCTAGAGG 5520 ATTTGCGCCT GCTCTTCAAA CAACAACCAG GAGGAAAGTA ACTAAAATCA TAAATCCCCC 5580 ATGGSCCTCC CTTATCATAT TTTTCTCTKT ASTGTTSTTT YACCCTSTTT CACTCTCACT 5640 GCACCCCCTC CATGCCGCTG TATGACCAGT AGCTCCCCTY ACCMAGAGTT TCTATGGAGA 5700 25 ATGCAGCGTC CCGGAAATAT TGATGCCCCA TCGTATAGGAG TCTTTSTAAG GGAACCCCC 5760 ACCTTCACTG CCCACACCCA TATGCCCCGC AACTGCTATC ACTCTGCCAC TCTTTGCATG 5820 CATGCAAATA CTCATTATTG GACAGGAAAA ATGATTAATC CTAGTTGTCC TGGAGGACTT 5880 GGAGTCACTG TCTGTTGGAC TTACTTCACC CAAACTGGTA TGTCTGATGG GGGTGGAGTT 5940 CAAGATCAGG CAAGAGAAAA ACATGTAAAA GAAGTAATCT CCCAACTCAC CSGGGTACAT 6000 30 GGCACCTCTA GCCCCTACAA AGGACTAGAT CTCTCAAAAC TACATGAAAC CCTCCGTACC 6060 CATACTCGCC TGGTAAGCCT ATTTAATACC ACCCTCACTG GGCTCCATGA GGTCTCGGCC 6120 CAAAACCCTA CTAACTGTTG GATATGCCTC CCCCTGAACT TCARGCCATA TGTTTCAATC 6180 CCTGTACCTG AACAATGGAA CAACTTCAGC ACAGAAATAA ACACCACTTC CGTTTTAGTA 6240 GGACCTCTTG TTTCCAATST GGAAATAACC CATACCTCAA ACCTCACCTG TGTAAAATTT 6300 35 AGCAATACTA CATACAAC CAACTCCCAA TGCATCAGGT GGGTAACTCC TCCCACACAA 6360 ATAGTCTGCC TACCCTCAGG AATATTTTTT GTCTGTGGTA CCTCAGCCTA TCGTTGTTTG 6420

AATGGCTCTT CAGAATCTAT GTGCTTCCTC TCATTCTTAG TGCCCCCYAT GRCCATCTAC 6480 ACTGAACAAG ATTTATACAG TTATGTCATA TCTAAGCCCC GCAACAAAAG AGTACCCATT 6540 CTTCCTTTTG TTATAGGAGC AGGAGTGCTA GGTGCACTAG GTACTGGCAT TGGCGGTATC 6600 ACAACCTCTA CTCAGTTCTA CTACAAACTA TCTCAAGAAC TAAATGGGGA CATGGAACGG 6660 5 GTCGCCGACT CCCTGGTCAC CTTGCAAGAT CAACTTAACT CCCTAGCAGC AGTAGTCCTT 6720 CRAAATCGAA GAGCTTTAGA CTYGCTAACC GCTGARAGAG GGGGAACCTG TTTATTTTTA 6780 GGGGAAGAAT GCTGTTATTA TGTTAATCAA TCCGGAATCG TCACTGAGAA AGTTRAAGAA 6840 ATTCSAGATC GAATACAACG TAKAGCAGAR GAGCTTCGAA ACACTGGACC CTGGGGCCTC 6900 CTCAGCCRAT GGATGCCCTG GATTCTCCCC TTCTTAGGAC CTCTAGCAGC TATAATATTG 6960 10 CTACTCCTCT TTGGACCCTG TATCTTTRAC CTCCTTGTTA ACTTTGTCTC TTCCAGAATC 7020 GAAGCTGTRA AACTACAAAT GGAGCCCAAG ATGCAGTCCA AGACTAAGAT CTACCGCAGA 7080 CCCCTGGACC GGCCTGYTAG CCCACGATCT GATGTTAATG ACATCAAAGG CACCCCTCCT 7140 GAGGAAATCT CAGCTGCACA ACCTCTACTA CGCCCCAATT CAGCAGGAAG CAGTTAGAGC 7200 GGTSGTCGGC CAACCTCCCC AACAGCACTT AGGTTTTCCT GTTGAGATGG GGGACTGAGA 7260 GACAGGACTA GCTGGATTTC CTAGGCTGAY TAAGAATCCY TAAGCCTAGS TGGGAAGGTG 7320 15 ACCACATCCA CCTTTAAACA CGGGGCTTGC AACTTAGYTC ACACCTGACC AATCAGAGAG 7380 CTCACTAAAA TGCTAATTAG GCAAAGACAG GAGGTAAAGA AATAGCCAAT CATYTATTGC 7440 MTGAGAGCAC AGCAGGAGGG ACAATGATCG GGATATAAAC CCAAGTYTTC GAGCCGGCAA 7500 CGGCAACCCC CTTTGGGTCC CCTCCCTTTG TATGGGAGCT CTGTTTTCAT GCTATTTCAC 7560 20 TCTATTAAAT CTTGCARCTG CR 7582

## (2) INFORMATIONS POUR LA SEQ ID NO: 12:

25 (i) CARACTERISTIQUES DE LA SEQUENCE:

- (A) LONGUEUR: 2563 paires de bases
- (B) TYPE: nucléotide
- (C) NOMBRE DE BRINS: simple
- (D) CONFIGURATION: linéaire

30

- (ii) TYPE DE MOLECULE: ADN
- (iii) HYPOTHETIQUE: NON
- 35 (xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 12:

ACTGCACTCT TCTGGTCCAT GTTTGTTACG GCTCGAGCTG AGCTTTTGCT CGCCATCCAC CACTGCTGTT TGCCACCGTT GCAGACCCAC TGCTGACTTC CATCCCTCTG GATCTGGCAG 120 5 GGTGTCTGCT GTGCTCCTGA TCCAGCGAGG GGCCCATTGC CACTCCCAAT CGGGCTAAAG 180 GCTTGCCATT GTTCCTGCAT GGCTAAGTGC CCAGGTTCAT CCTAATTGAG CTGAACACTA 240 GTCACTGGGT TCCACAGTTC TCTTCCATGA ACCACGGCTT TTAATAGAGC TATAACACTC 300 10 ATCGCAAGGC CCAAGATTCC ATTCCTTGGA ATCTGTGAGG CCAAGAACCC TAGGTCAGAG 360 AACACGAGGC TTGCCACCAT CTTGGAAGCA GCCTGCCACC ATCTGGGAAG CGGCCTGCCA 420 15 CCATCTTGGA AGCCGCCCGC CACCATCTTG GGAGCTCTGG GAGCAAGGAC CTCCCCGCAA 480 CCCAGTAACA TTTAGCGACC ACGAAGGGAC CTCCAAAGCG GTAATATTGG ACCACTTTCA 540 CTTGCTATTC TGTCCTATCC TTCCTTAGAA TTGGAGGAAA ATACCGGACA CCTGTCGGCC 600 20 GGTTAAAAAC GATTAGCGTG GCCTCCGGAC TTAAGAATCA GGTGTGAGGC TATCTGGGGA 660 AGGGCTTTCT AACAACCCCC AACCRTTCTG GGTTGGGAAT GTTGGTCTGC CTGGAGCCAG 720 25 CTTCCACTTT CAATTTCCT GGGGAAGCCA AGGGCCGACT AGAGGCAGAA AGCTGTTGTC 780 CCAAATTCCC GGCAGTAGCC GGTTGAGATC ATGGCGCAGC CAGAAGTCTT TACTCCACAG 840 TCACCCATGC ATGCGCCCCT ATCTTTCCTT CTGACCCATA CCTCCTGGGT CCTAACCATG 900 30 ACTITCTTAA AAGGGTAGCC CCAAAATTCT CCTTACCTCT GAATCTACTT CCTCTGATCC 960 CTGCCTCCTA GGTGCTAATG GTTCAGACTT TCATTTCCTC TAGCAAGTTG TATYTCCAAA 1020 35 GGGATATAAG GAAGCTCTAC ACTGTATCCT TAGGCATCTA GGCTCTAAAC CCAGGGAGTC 1080

TTGTCCCTGA TGTCCCAACC GATTTAGGTA TATAGTTCTC GACATGGGCA GTTATGTGGG 1140 ACCCATTCCC CACCACCCTT GCCAGGGCCC CAAGTTTGTA AATGGCTAAG AGAGGAAAGT 1200 GAGAGAGAG GAGACAGAGA GAGAGGGAGA GACAGAGAGA GAGACAGAGA 1260 GGAGAGAGAC ACAGAGAGGG GAGAGACACA GAGAGGAGAA GGGGGCAGAG AGACCAAGAG 1320 GGAGTCYMAG AGAGAGAA AGAAGAAGAA ATAGTAGAAA AAAAAGTGTG CCCTATTCCT 1380 10 TTAAAAGCCA GGGTAAATTT AAAAAACCTA TACTTGATAA TTGAAGGTCT TCTCCATGAC 1440 CCTGTAACAC TCTAATACTA CCTTGTTCTC AGTGTAAACA AGGGTGTTAG CCTGAAAACA 1500 CTGAGACCGC TGACACCCAT AGCTTTCCTA TAAAAAATCC TTAACCCAGT AACCCGCAGA 1560 15 TGGCCCGCAT GCATTCAATC TGTAGTGGCA ACTGCTTTGC TAACAAGAAT AAAGTGGAAA 1620 AGTAACTTTT AGAGGAAACC TCATTGTGAG CACACCTCAC CAGTTCAGAA TTATTCTAAG 1680 20 .. TCAAAAAAGC AAAAAGGTAG CTTACTAACT CAAAAATCTT AAAGTATGGG GTTATTTTGT 1740 TAGAAAAAGG TAATTTAACA CTAATCACTG ATAATTCCCT TAACCCAGAA GATTTCCTAA 1800 25 CAGGAGATTT AAATCTTAAT TACCATACAA AGGTCTGACC AGACCTAGGA GGAACTCCCT 1860 TCAGTACAGG ATGATAGATG GTTCCTCCCA GGTGAATGAA AAAAAAATCA CAATGGGTAT 1920 TCAGTAATTG ATAGGGAGAC TCTTGTGGAA GCAGAGTTAG AAAAACTGCC TAATAATTGG 1980 30 TCTCCCCAAA CCTGCGAGCT GTTTGCACTC AGCCAAGCCT TAAAGTI DIE GERMANTCAA 2040 AAAGATTATC TCAATCCTGA CTCAAAAGGT TACCTACACC CTCTGTGAAA CGAATTTACT 2100 TAAGAACTGT TTATGGGACT GCATCTTGAT GGGGCAGCTG GGILGICATG FLATTAGTCAG 2160 35

	GAATGCAGCC	TAGCTCTAGG	ACTCACCCCT	GAGCACAAAG	GCAATGTTGG	GCATGCTGG••	2220
	AAAGGACCAC	TAGAATCCAG	CAGTCCGAAC	CCTTTCTTTG	GGTTAAGAAA	GGCGGGAAAA	2280
5	CAGGCGCAGG	ACTGCTACAT	TGGTAAGCGT	AACTAATCCA	ATAAGCAGAG	GTCCATGGGT	2340
	GGTGACACAC	TCTGGAAAGG	AATAAGCATT	AGRACCATAG	AGGACGCTCT	ACGACTAATG	2400
1:0	CTCGTCGGAA	AATGACTAGA	GGTGCTGGCA	TCCCTATGTT	CTTTTTTCAG	ATGGGAAAT <b>G</b>	2460
,—-	TTCCCCCTCA	AGGCAAAAAC	ACCCCTAAGA	TGTATTCTGG	ACAATTGGGA	CCAATTTGAC	2520
	CCTCAGACTC	TAAGAAAGAA	ACGACTTATA	TTCTTCTGCA	GTG		2563

15

- (2) INFORMATIONS POUR LA SEQ ID NO: 13:
  - (i) CARACTERISTIQUES DE LA SEQUENCE:
    - (A) LONGUEUR: 2585 paires de bases
- 20 (B) TYPE: nucléotide
  - (C) NOMBRE DE BRINS: simple
  - (D) CONFIGURATION: linéaire
  - (ii) TYPE DE MOLECULE: ADN

25

35

- (iii) HYPOTHETIQUE: NON
- (xi) DES . MANN DE LA SEQUENCE: SEQ 'D NO: 13:
- 30 TCAGGGATAG CCCCCATCTA I GCCA CACA CACA CAT 60

ACTTGGACAC TO TGTCCTT TGGTA, STGG ATGATCTACT TTTAGCCACC TGTTCAGAAA 120

CCTTGTGCCA TCAAG CAAGTGCTCT TAT TAC ACCTCT AGG 180

TTTCCAAACC AGAGGCT .IAC AC AGGTTAT ATT TTTAGGG CTAAAATTAT 240

CCAAAGGCAC CAGGGCCCTC AGTGAGGAAC GTATCCAGCC TATACTGGCT TATCCTCATC 300 CCAAAACCCT GAAGCAATTA AGAGGGTTCC TTGGCATAAA AGGCTGCTGT TGAATATGGA 360 5 TTCCCAGGTA CAATGAAATA GCCAGGCCAT TATACACACT AATTACGGGA ACTCAGAAAG 420 CCAATACCCA TTTAGTAGAA TGGACACCTG AAGCAGAAGC GGCTTTCCAG GCCCTAAAGA 480 10 AGGCCCTAAT CCAAGCCCCA GTGTTAAGCT TGCCAATGGA GCAAGACTTT TCTTTATATG 540 TCACAGAAAA AAAAACAGGA ATAGCTCTAG AAGTCCTTAC ACAGGTCCGA GGGACCAGCT 600 TACAACACAT GGCATACCTG AGTAAGGAAA CTGATGTAGT GGCAAAGGGT TGGACTCATT 660 15 GTTTACAGGT AGTGGCAGCA GTAGCAGTCT TAGCATCTGA AGCAGTTAAA ATGATACAGG 720 GAAGANATCT TACTGTGTGG ACATCTCATG ATGTGAACGG CATACTCACT GCTAAAGGAG 780 20 ACTGTGGCTG TCAGACAACC ATTTGCTTAA ATATCAGGCT CTATCACTTG AANGGCCAGT 840 GCTGCCACTG TGCACTTGTG CAACTCTTAA CCCACCCACA TTTCTTCCAG ACAATGAAGA 900 AAAGATAGAA CATAACTGTC AACAAGTGAT TGTTCAAACC TACACCGCTC GAAGGGACCT 960 25 TCTAGAGGTT CCCTTGACTG ATCCTGAGCT CAACTTCTAT ACTGATGGAA GTTCCTTTTG 1020 TAGAAAAAGG ACTTCGAAAG GCGGGTATGC AGTGGCCAGT GATAATGGAA TACTTGAAAG 1080 TAATCCCTTC ACTCCAGAAA CTAGCATTCA GCTGGCAGAA TTAATAGCCT TCACTTGGGC 1140 ATTAGAACAC AGGAGAAGGA AAAGGAGTAA ATATATATAC AGACTCCAAG TATGCTTACT 1200 TAGTCCTCCA TGCCCATGCA GCAATATAGA GAGAAAGCGA ATTCCTAACT TCTGAGGGAA 1260 35 CACCTATCAA ACATCAGGAA GCCATTAGGA GATTATTACT GGCTGTACAG AAACCTAGAG 1320

GTGGCAGTCT TACATGGCCG AGATCATCAG AAAGGAAAAG AAAGGGAAAT AGAAGGGAAC 1380 TGCCAAGTGG ATATTGAAGC CAAAAGAGCT GCAAGGCGGG ACCCTCCATT AGAAATGCTT 1440 5 ATAGAAGGAC CCCTAGTACA GGGCAATCCC CTTCAGGAAA CCAAGCCCCA ATACTCAGCA 1500 GAAGAAATGG AATGGGGAAC CTCATGAGGA CATAGTTTCC TCCCCTCAGG ATGGCTAGCC 1560 10 ACCAAAGAAG GAAAAATACT TTTGCCTGCA GCTAACCAAT GGAAATTACT TAAAACCCTT 1620 CACCAAACCT TTCGCTTAGG CATTGATAGC ACCCATCAGA TGGCTAAATC ATTATTTACT 1680 AGACCACACC TTTTCAAAAC TATCAAGCAG ACAGTTAGGG CCTGTGAAGT GTGCCAAAGA 1740 15 AATAATCCCC TGCCTTATCG CCAAACTCCT TCAGGAGAAA AAAGAACAGG CCATTACCCA 1800 GGAGAAGAGT GGCAACTAGA TTTTACCCAC ATGCCCAAAT CTCAGGGATT TCAGTATCTA 1860 20 CTAGTCTGGG TAGATACTTT CACTGGTTGG GCGGAGGCCT TCCCTTGTAG GACAGAACAG 1920 GCCCATGAGG TAATAAAGGC ACTAATTCAT GAAATAATTC CCAGATTTGG ATTTCCCCAA 1980 GGCTTACAGA GTGATAACGG CCCCACTTTC AAGGCTACAG TAACCCAGGG AGTATCCCAG 2040 25 ACATTAGACA TACAATATCA CTTACACTGA GCCCGGAGGC CACAATCCTC AGGAAAGTTG 2100 AGAAAATGAA TGAAACGCTC AAATGACATC TAAAAAAGCT AACCTAAGAA ACCCACCTCT 2160 30 CATGGTTTGC TCTGTTGCCT ATAGCCTTAG TAAGAATCCG AAACTCTCCC CAAAAAGCGG 2220 GACTCAGCCC ATACGAAATG CTGTATGGAC GGCCCTTCCT AACCAATGAC CTTGTGCTTG 2280 ACCTAGAGAT GGCCAACTTA GTTGCAGATA TCCCTCCTTA GCCAAATATC AACAAGTTCT 2340 35 TAAAACGTCA CAGGGAACCT GTCCCTGAGA GGAGGGAAAG GAATTATTCC AACCTGGTGA 2400

CATGGTATTA GTGAAGTCCC TTCCCTCCAA CTCCCCATCC CCTGGATACA TCCTGGGAAG 2460

GACCCTACTC AGTCATTTTA TCTATCCCAA CCGCGGTTAA AATGGCTGGA GTAGAATCTT 2520

GGATACATCA CATTCGAGTC AAACCCTAGA TACTGCCACA AGGAACCTGA AAATCCAGGA 2580

GACAA 2585

10

5

- (2) INFORMATIONS POUR LA SEQ ID NO: 14:
  - (i) CARACTERISTIQUES DE LA SEQUENCE:
    - (A) LONGUEUR: 2575 paires de bases
- 15 (B) TYPE: nucléotide
  - (C) NOMBRE DE BRINS: simple
  - (D) CONFIGURATION: linéaire
  - (ii) TYPE DE MOLECULE: ADN

20

- (iii) HYPOTHETIQUE: NON
- (xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 14:
- 25 GGGATAGCCC CCATCTATT GGCCAGGCAT TAGCCCAAGA CTTGAAGCCA ATTCTCATAC 60

  CTGGACACTC TTCTCCTTTG GTATGTGGAT GATTTACTTT TAGCTTCCTG TTCAGAAACC 120

  TTGTGCCATC AAGCCACCCA AGCACTCTTA AATTTCCTCG CTACCTGTGG CTACAAGGTT 180

  30

  TCCAAACCAA AGACCCAGCT CTGCTCACAG CAGGTTAAAT ACTTGGGGCT AAAATTATCC 240

  AAAGGCACCA GGGCCCTCAG TGAGGAACGT ATCAAGCCTA TACTGGCTTA TCCTCATCCC 300

  35 CAAATCCTAA AGCAACTAAG AGAGTTCCTT AGCATAACAG GTTTCTGCTG AATATGGATT 360

CCCAGGTATG GCAAAATAGC CAGACCATTA TATACGCTAA TTAAGGAAAC TCAGAAAGCC 420 AATACCCATT TAGTAAGATG GATACCTGAA GCAGAAGCAG CTTTCCAGGC CCTAAAGAGG 480 GCCCTAACCC AAGCCCCAGT GTTAAGCTTG CCAACAGGGC AAGACTTTAC TTCGTATGTC 540 ACAGAAAAA CAGGAAATAG CTCTAGGAGT CCTTACACAA GTCTGAGGGA TGAGCTTGCA 600 ACCCATGGCA TACCTGAGTA AGGAAATTGA TGTAGTGGCA AAGGGTTGGC CTCATTGTTT 660 10 ATGGGTAGTG GCGGCAGTAG CAGTCTTAGC ATCTGAAGCA GTTAAAATGA TACAGGGAAG 720 AGATCTTACT GTGTGGACAT CTCATGATGT GAATGGCATA CTCACTGCTA AAGGAGACTT 780 GTGGCTGTCA GACAACCATT TACTTAAATA TCAGGCTGTA TTACTTGAAG GGCCAGTGCA 840 GCAACTGCGC AGTTGTGCAG CTCTTAACCC AGCCACATTT CTTCCAGACA ATGAAGATAG 900 AACATAACTG CCAACAAGTA ATTTCTCAAA CCTAGGCCGC TCGAGGGAAC CTTTTAGAGG 960 20 TTCCCTTAAC TGATCCCGAC CTCAACTTGT ATACTGATGG AAGTTCCTTT GTAGAAAAAG 1020 GACTTTGAAA AGTGGGGTAT GCAGTGCTCA GTGATAATGG AATACTTGAA AATAATCCCT 1080 TCATTCCAGG AACCAGCGTT CAGCTGGCAG AATTAATAGC CCTCACTCGG GCATTAGAAT 1140 TAGGAGAAGG AAAAAGGGTA AATACACATA CAGATTCTAA GTATGTTTAC TTAGTCCTCC 1200 GTGCCCACGC AGCAATATGG AGAGAAAGGG AATGCTTAAC TTCTGAGGGA ACACCTATCA 1260 30 AACATCAGGA AGTTATTAGG AGATTATTAT TGGCTATACA GAAACCTAAA GAGGTGGCAG 1320 TCTTACACTG CTGGGGTGGT CAGAAAGAAA AGGAAAGGGA AATAAAAGGG AACTGCCAAG 1380 35 CGGATATTGA AGCCAAAAGA GCCGCAAGGC AGGACCCTCC ATTAGAAATG CTTATAGAAG 1440

GACCCCTAGT ATGGGGTAAT CCCCTCCGGG AAACCAAGCC CCAATACTTA GAAAAAGAAA 1500 TAGAATGGGG AACCTCACGA GGACATAGTT TCCTCCCCTC AGGATGGCTA GCCACCGAAG 1560 AAGGAAAAAT ACTTTTGCCT GCAGCTAACC AATGGAAATT ACTTAAAACC CTTCACCAAA 1620 CCTTTCACTT AGACATTGAT AGCACCCATC AGATGGCCAA ATCATTATTT ACTGGACCAG 1680 GCCTTTTCAA AACTATCAAG CAGCTAGTCA GGGCCTGTGA AGTGTGCCGA AGAAATAATC 1740 10 CCATGCCTTA TCACCAAGCT CCTTCAGGAG AACAAAGAAC AGGCCATTAC CCAGGAGAAG 1800 RVTGGCAACT AGATTTTACC CACATGCCCA AATCTCAGGG ATTTCAGTAT CTACTAGTTT 1860 GGGTAGATAC TTTCACTGGT TGGGCAGAGA CCTTCCCCTG TAAGACAGAA AAGTCCCAAG 1920 15 AGGTAATAAA GGCATTAGTT CATGAAATAA TTCCCAGATT CAGACTTCCC TGAGGCTTAC 1980 AGAGTGACAA TGGCCCTGCT TTCAAGGCTA CAGTAACCCA GGAGTATCCC AGGTGTTAGG 2040 20 TATACAATAT CACTTACACT GCGCCTGGAG GCAGTCCTCA GGGAAGGCCG AGAAACTGAA 2100 TGAAACACTC AAACGACATC TAAAAAAAGC TAACCCAGGA AAACCACCTC ACATGGCCTG 2160 25 CTCTGTTGCC TATAGCCTTA CTAAGAATCC AAAACTCTCC CCAAAAAGCA GGACTTAGCC 2220 CATACGAAAT GCTATATGGA TAGCCCTTCC TAACCAATGA CCTTGTGCTT GACTGAGAGA 2280 GAGCCAACTT AGTTGCAGAC ATCACCTCCT TATCCAAATA TCAACAAGTT CTTAAAACAT 2340 30 TACAAGGAGC CTGTCCCCGA GAAGAGGGGA AGGAACTATT CCACCCTGGT GACATGGTAT 2400 TAGTCAAGTC CCTTCCCTCT AATTCTCATT GCCTAGATAT ATCCTGGGAA GGACCCTACC 2460 35 CAGTC STAC OF ACCCULATAR A SSCE AGTGGAC STGGATASATC 2520

ACACTCGAGT	CAAACCCTGG	ATATTACCAA	AGGAACCTGA	AAATCCAGGA	CACAZ

2575

(2)	INFORMATIONS	POUR	LA	SEQ	ID	NO:	15:
-----	--------------	------	----	-----	----	-----	-----

5

- (i) CARACTERISTIQUES DE LA SEQUENCE:
  - (A) LONGUEUR: 783 paires de bases
  - (B) TYPE: nucléotide
  - (C) NOMBRE DE BRINS: simple

10

- (D) CONFIGURATION: linéaire
- (ii) TYPE DE MOLECULE: ADN
- (iii) HYPOTHETIQUE: NON

15

(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 15:

	TGAGAGACAG	GACTAGCTGG	ATTTCCTAGG	CYGACTAAGA	ATCCYTAAGC	CTAGSTGGGA	60
	AGGTGACCAC	RTCCACCTTT	AAACACGGGG	CTTGCAACTT	AGYTCACACC	TGACCAATCA	120
20	GAGAGCTCAC	TAAAATGCTA	ATTAGGCAAA	GACAGGAGGT	AAAGAAATAG	CCAATCATYT	180
	ATTGCMTGAG	AGCACAGCAG	GAGGGACAAY	RATCGGGATA	TAAACCCARG	YHTTCGAGCY	240
	GGCAACRGCA	GMCCCCCTTT	GGGTCCCYTC	CCTTTGTATG	GGAGCTCTGT	TTTCATGCTA	300
	TTTCACTCTA	TTAAATCTTG	CARCTGCRCT	CTTCTGGTCC	ATGTTTCTTA	CGGCTYGAGC	360
	TGAGCTTTYG	CTCRCCRTCC	ACCACTGCTG	TTTGCCRCCA	CCGCANACCY	GCCGCTGACT	420
25	CCCATCCCTC	TGGATCMTGC	AGGGTGTCCG	CTGTGCTCCT	GATCCAGCGA	RGCRCCCATT	480
	GCCGCTCCCA	ATYGGGCTAA	AGGCTTGCCA	TTGTNCCTGC	AYGGCTAAGT	GCCTGGGTTY	540
	RTYCTAATTG	AGCTGAACAC	TANTCACTGG	GTTCCATGGT	TCTCTTCTGT	GACCCACRGC	600
	TTCTAATAGA	RCTATAACAC	TYACCRCATG	GCCCAAGRTT	CCATTCCTTG	GAATCCRTRA	660
	RGSCAACGAA	CYCCASGTCA	GAGAAYACGA	RGCTTGCCAC	CATCTTGGAA	GCGGCCTGCT	720
30	ACCATCTTGG	AAGTGGTTCA	CCACCATCTT	GGGAGCTCTG	TGAGCAAGGA	CCCCCMRGTR	780
	ACA						783

(2) INFORMATIONS POUR LA SEQ ID NO: 16:

35

(i) CARACTERISTIQUES DE LA SEQUENCE:

(A) LONGUEUR: 20 paires de bases

	(B) TYPE: nucléotide	
	(C) NOMBRE DE BRINS: simple	
	(D) CONFIGURATION: linéaire	
5		-
	(ii) TYPE DE MOLECULE: ADN	
	(iii) HYPOTHETIQUE: NON	
10	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 16:	: • •
		***
	TGTCCGCTGT GCTCCTGATC	20
	·	
• -		
15	(2) INFORMATIONS POUR LA SEQ ID NO: 17:	
	(i) CADACEDRACED CONTROL DE LA CRESTANTION	
	(i) CARACTERISTIQUES DE LA SEQUENCE:	
	<ul><li>(A) LONGUEUR: 21 paires de bases</li><li>(B) TYPE: nucléotide</li></ul>	
20	(C) NOMBRE DE BRINS: simple	
	(D) CONFIGURATION: linéaire	
	(5) Controlling Theatre	
	(ii) TYPE DE MOLECULE: ADN	
	. , , , , , , , , , , , , , , , , , , ,	
25	(iii) HYPOTHETIQUE: NON	
	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 17:	
	ATGCACTCTG GCTGGGCCAA T	21
30		
	(2) INFORMATIONS POUR LA SEQ ID NO: 18:	
	(i) CARACTERISTIQUES DE LA SEQUENCE:	
35	(A) LONGUEUR: 21 paires de bases	

(B) TYPE: nucléotide

(C) NOMBRE DE BRINS: simple

	(D) CONFIGURATION: linéaire	grand of the second
5	(ii) TYPE DE MOLECULE: ADN	
J	(iii) HYPOTHETIQUE: NON	
	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 18:	
10	ACCATTTGAC CCTCAGACAC T	21
	(2) INFORMATIONS POUR LA SEQ ID NO: 19:	
15	(i) CARACTERISTIQUES DE LA SEQUENCE:  (A) LONGUEUR: 24 paires de bases  (B) TYPE: nucléotide  (C) NOMBRE DE BRINS: simple	
20	(D) CONFIGURATION: linéaire	
ė	(ii) TYPE DE MOLECULE: ADN  (iii) HYPOTHETIQUE: NON	
25	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 19:	a <del>te</del> "
	AACCCTTTGC CACTACATCA ATTT	24
30	(2) INFORMATIONS POUR LA SEQ ID NO: 20:	
	(i) CARACTERISTIQUES DE LA SEQUENCE:	·
	(A) LONGUEUR: 21 paires de bases	
	(B) TYPE: nucléotide	•
35	(C) NOMBRE DE BRINS: simple	

(D) CONFIGURATION: linéaire

	(ii) TYPE DE MOLECULE: ADN	
5	(iii) HYPOTHETIQUE: NON	
J	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 20:	
	TCAGGGATAG CCCCCATCTA T	21
10	(2) INFORMATIONS POUR LA SEQ ID NO: 21:	
	(i) CARACTERISTIQUES DE LA SEQUENCE:	
	(A) LONGUEUR: 22 paires de bases	
15	(B) TYPE: nucléotide	
	(C) NOMBRE DE BRINS: simple	
	(D) CONFIGURATION: linéaire	
20	(ii) TYPE DE MOLECULE: ADN	
	(iii) HYPOTHETIQUE: NON	
	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 21:	
25	TTGTCTCCTG GATTTTCAGG TT	22
	(2) INFORMATIONS POUR LA SEQ ID NO: 22:	
30	(i) CARACTERISTIQUES DE LA SEQUENCE:	
	(A) LONGUEUR: 20 paires de bases	
	(B) TYPE: nucléotide	
	(C) NOMBRE DE BRINS: simple	
	(D) CONFIGURATION: linéaire	
35		
	(ii) TYPE DE MOIECULE. ADM	

	(111) HYPOTHETIQUE: NON	
	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 22:	
5	GGACCCTACC CAGTCATTTT	20
	(2) INFORMATIONS POUR LA SEQ ID NO: 23:	
10		
	(i) CARACTERISTIQUES DE LA SEQUENCE:	
	(A) LONGUEUR: 20 paires de bases	
	(B) TYPE: nucléotide	
	(C) NOMBRE DE BRINS: simple	
15	(D) CONFIGURATION: linéaire	
	(ii) TYPE DE MOLECULE: ADN	
	(iii) HYPOTHETIQUE: NON	
20		
	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 23:	
	AMONGON GON GNOCCONGNO	
	ATCAGGAGCA CAGCGGACAC	20
25		
23	43) INDONVENTONG BOUR IN CRO. ID NO. 24.	,
	(2) INFORMATIONS POUR LA SEQ ID NO: 24:	
	(i) CARACTERISTIQUES DE LA SEQUENCE:	
	(A) LONGUEUR: 22 paires de bases	
30	(B) TYPE: nucléotide	
	(C) NOMBRE DE BRINS: simple	
	(D) CONFIGURATION: linéaire	
	(ii) TYPE DE MOLECULE: ADN	
35		
	(iii) HYPOTHETIQUE: NON	

	(AT) DESCRIPTION DE LA SEQUENCE. SEQ ID NO: 24:	
5	GGACATCCAA AGTGATACAT CC	22
	(2) INFORMATIONS POUR LA SEQ ID NO: 25:	
	(i) CARACTERISTIQUES DE LA SEQUENCE:	
10	(A) LONGUEUR: 21 paires de bases	
	(B) TYPE: nucléotide	
	(C) NOMBRE DE BRINS: simple	
	(D) CONFIGURATION: linéaire	
15	(ii) TYPE DE MOLECULE: ADN	
	(iii) HYPOTHETIQUE: NON	
20	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 25:	
20	AATGTATGGC CTGAAGTGCA G	21
	(2) INFORMATIONS POUR LA SEQ ID NO: 26:	
25		
	(i) CARACTERISTIQUES DE LA SEQUENCE:	
	(A) LONGUEUR: 22 paires de bases	
	(B) TYPE: nucléotide	
	(C) NOMBRE DE BRINS: simple	
30	(D) CONFIGURATION: linéaire	
	(ii) TYPE DE MOLECULE: ADN	
	/ 1 1 1 LYDOTUPTIOUP: NON	
35	(iii) HYPOTHETIQUE: NON	
. J	/vil DESCRIPTION DE LA SECUENCE. SEC 15 MO. 24.	
	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 26:	

22

CTTCCCAGGA TGTATCACTT TG

5	(2) INFORMATIONS POUR LA SEQ ID NO: 27:	
	(i) CARACTERISTIQUES DE LA SEQUENCE:	
	(A) LONGUEUR: 24 paires de bases	٠
	(B) TYPE: nucléotide	
10	(C) NOMBRE DE BRINS: simple	
	(D) CONFIGURATION: linéaire	
	(ii) TYPE DE MOLECULE: ADN	
15	(iii) HYPOTHETIQUE: NON	
٠	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 27:	
	CACTGCAGAA GAATATAAGT CGTT	24
20		
	(2) INFORMATIONS POUR LA SEQ ID NO: 28:	
	(i) CARACTERISTIQUES DE LA SEQUENCE:	
25	(A) LONGUEUR: 21 paires de bases	
	(B) TYPE: nucléotide	
	(C) NOMBRE DE BRINS: simple	
	(D) CONFIGURATION: linéaire	
30	(ii) TYPE DE MOLECULE: ADN	f
	(iii) HYPOTHETIQUE: NON	
	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 28:	
35	GCTTCCAAGA TGGTGGCAAG C	21

#### (2) INFORMATIONS POUR LA SEQ ID NO: 29:

- (i) CARACTERISTIQUES DE LA SEQUENCE:
- 5 (A) LONGUEUR: 678 paires de bases
  - (B) TYPE: nucléotide
  - (C) NOMBRE DE BRINS: simple
  - (D) CONFIGURATION: linéaire
- 10 (ii) TYPE DE MOLECULE: ADN
  - (iii) HYPOTHETIQUE: NON
  - (xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 29:

15 TCAGGGATAG CCCCCATCTA TTTGGCCAGG CATTAGCCCA AGACTTGAGC CAGTTCTCAT 60 ACCTGGATAT TCTTGTCCTT TGGTATGCGG ATGATTTACT TTTAGCCGCC CGTTCAGAAA 120 20 CCTTGTGCCA TCAAGCCACC CAAGTGCTCT TAAATTTCCT CGCCACCTGT GGCTACAAGG TTTCCAAACC AAAGGCTCAG CTCTGCTCAC AGCAGAAGGC TATTTACCCT AAATACTTAG GGCTGAAATT ATCCAAAGGC ACCAGGGCCC TCAGTGAGGA ATGTATCCAG CCTATACTGG 300 25 CTTATCCTTA TCCCAAAACC CTAAAACAAC TAAGAAGGTT CCTTGGCATA ATAGGCATAA CAGGCATAAC AGGTTTCTGC TGAATATGGA TTCCCAAGTA CGGCAAAATA GCCAGACCAT 420 30 TATATACACT AATTAAGGAA ACTCAGAAAG CCAATACCCA TTTAGTAAGA TGGACACCTG AAGCAGAGGC AGCTTTCCAG GCCGTAAAGA ACACCCTAAC CCAAGCCCCA GTGTTAAGCT TGCCAGCGGG GCAAGACTTT TCTTTCTGTG TCACAGAAAA AATAGGAATA GCTNTAGGAG 600 35 TCCTTACACA GGTCCGAGGG ACCAGCTTGC AACCCATGGC ATACCTGAGT AAGGAAATTG 660

	ATGTAGTGGC AAAGGGTT	678
5	(2) INFORMATIONS POUR LA SEQ ID NO: 30:	
•	(i) CARACTERISTIQUES DE LA SEQUENCE:  (A) LONGUEUR: 536 paires de bases	
	(B) TYPE: nucléotide	
10	(C) NOMBRE DE BRINS: simple	
	(D) CONFIGURATION: linéaire	
	(ii) TYPE DE MOLECULE: ADN	
-		
15	(iii) HYPOTHETIQUE: NON	
	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 30:	
	CCAATCTCCA TGTTGTATCC CCTTCCCCAA CTAATAAGGA CCCCCCTTTC AACCCAAACA	60
20		
	GTCCAAAAGG ACATAGACAA AGGAGTAAAC AATGAACCAA AGAGTGCCAA TATTCCCTGG	120
	MMNMOGNOGO MOGNNOGO COGNGNON MMOGGGGGGAN CONCLUMAN MOGNGGAN	
	TTATGCACCC TCCAAGCGGT GGGAGAAGAA TTCGGCCCAG CCAGAGTGCA TGTACCTTTT	180
25	TCTCTCTCAC ACTTGAAGCA AATTAAAATA GACCTAGGTA AATTCTCAGA TAGCCCTGAT	240
	TOTOTOTOM NOTTOMOON MATTHEMATIN CHOOMINGOTH MATTOTOMON TAGGEORGAT	240
	GGCTATATTG ATGTTTTACA AGGATTAGGA CAATCCTTTG ATCTGACATG GAGAGATATA	300
	ATATTACTGC TAAATCAGAC GCTAACCTCA AATGAGAGAA GTGCTGCCAT AACTGGAGCC	360
30		
	CGAGAGTTTG GCAATCTCTG GTATCTCAGT CAGGTCAATG ATAGGATGAC AACGGAGGAA	420
	ACACA ACCAM MOCCOLOGO COLOGO COLOGO COMO COMO MACOMO MACOMO MACONO CALO	400

536

35 GAATCAGAAC ATGGAGATTG GTGCCGCAGA CATTTAAAGC TTTCCCCGGG TACCGA

### (2) INFORMATIONS POUR LA SEQ ID NO: 31:

(i)	CARACTERISTIC	QUES DE	LA	SEQUENCE:
-----	---------------	---------	----	-----------

(A) LONGUEUR: 591 paires de bases

- (B) TYPE: nucléotide
- (C) NOMBRE DE BRINS: simple
- (D) CONFIGURATION: linéaire
- 10 (ii) TYPE DE MOLECULE: ADN

5

35

- (iii) HYPOTHETIQUE: NON
- (xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 31:

15 CCATGGCCAT CTACACTGAA CAAGATTTAT ACAATCATGT CGTACCTAAG CCCCACAACA 60 AAAGAGTACC CATTCTTCCT TTTGTTATCA GAGCAGGAGT GCTAGGCAGA CTAGGTACTG 120 20 GCATTGGCAG TATCACAACC TCTACTCAGT TCTACTACAA ACTATCTCAA GAAATAAATG 180 GTGACATGGA ACAGGTCACT GACTCCCTGG TCACCTTGCA AGATCAACTT AACTCCCTAG 240 CAGCAGTAGT CCTTCAAAAT CGAAGAGCTT TAGACTTGCT AACCGCCAAA AGAGGGGGAA 300 25 CCTGTTTATT TTTAGGAGAA GAACGCTGTT ATTATGTTAA TCAATCCAGA ATTGTCACTG 360 AGAAAGTTAA AGAAATTCGA GATCGAATAC AATGTAGAGC AGAGGAGCTT CAAAACACCG 420 30 AACGCTGGGG CCTCCTCAGC CAATGGATGC CCTGGGTTCT CCCCTTCTTA GGACCTCTAG 480 CAGCTCTAAT ATTGTTACTC CTCTTTGGAC CCTGTATCTT TAACCTCCTT GTTAAGTTTG 540 TCTCTTCCAG AATTGAAGCT GTAAAGCTAC AGATGGTCTT ACAAATCTAG A 591

(2) INFORMATIONS POUR LA SEQ ID NO: 32:

	(i) CARACTERISTIQUES DE LA SEQUENCE:	•
	(A) LONGUEUR: 364 paires de bases	
5	(B) TYPE: nucléotide	
	(C) NOMBRE DE BRINS: simple	
	(D) CONFIGURATION: linéaire	
10	(ii) TYPE DE MOLECULE: ADN	
	(iii) HYPOTHETIQUE: NON	
	(xi) DESCRIPTION DE LA SEQUENCE: SEQ ID NO: 32:	
15	CTAACCTGAG GATCCAGCAG CAGGACTGAG GGTGCCCGGG GCAAGTGCCA GCCCATGCCA	60
	TCACCCTCAG AGCCCCGGGT ATGTTTGACC ATTGAGAGCC AGGAAGTTAA CTGTCTCCTG	120
20	GACACTGGCG CAGCCTTCTC AGTCTTACTT TCCTGTCCCA GACAATTGTC CTCCAGATCT	180
	GTCACTATCC GAGGGGTCCT AGGACAGCCA GTCACTACAT ACTTCTCTCA GCCACTAAGT	240
	TGTGACTGGG GAACTTTACT CTTTTCACAT GCTTTTCTAA TTATGCCTGA AAGCCCCACT	300
25	CCCTTGTTAG GGAGAGACAT TTTAGCAAAA GCAGGGGCCA TTATACACCT GAACAAGCTT	360
	GAAA	364
30	(2) INFORMATIONS POUR LA SEQ ID NO: 33:	
	(i) CARACTERISTIQUES DE LA SEQUENCE:	
	(A) LONGUEUR: 538 acides aminés	
	(B) TYPE: acide aminé	
35	(C) NOMBRE DE BRINS: simple	

(D) CONFIGURATION: linéaire

	(ii)	TYP	E DE	MOL	ECUL	E: p	roté	ine								
5	(iii)	НУР	отне	TIQU	E: N	ON										
5	(×i)	DES	CRIP	TION	DE	LA S	EQUE	nce:	SEQ	ID	NO:	33:				
	Met	Gly	Leu	Pro	Tyr	His	Ile	Phe	Leu	Cys	Ser	Val	Leu	Ser	Pro	Cys
10	1				5					10					15	_
10	Phe	Thr	Leu	Thr 20	Ala	Pro	Pro	Pro	Cys 25	Arg	Суз	Met	Thr	Ser 30	Ser	Ser
15	Pro	His	Pro 35	Glu	Phe	Leu	Trp	Arg	Met	Gln	Arg	Pro	Gly 45	Asn	Ile	Asr
	Ala	Pro 50	Ser	Tyr	Arg	Ser	Leu 55	Ser	Lys	Gly	Thr	Pro 60	Thr	Phe	Thr	Ala
20	His	Thr	His	Met	Pro	Arg	Asn	Cys	Tyr	His	Ser	Ala	Thr	Leu	Сув	Met
•	65		· 😘			70					75					80
	· His	Ala	Asn	Thr	His 85	Tyr	Trp	Thr	Gly	Lys	Met	Ile	Asn	Pro	Ser 95	Сув
25	<i></i>															
	Pro	Gly	Gly	Leu 100	Gly	Val	Thr	Val	Cys 105	Trp	Thr	Tyr	Phe	Thr 110	Glņ	Thr
30	Gly	Met	Ser 115	Asp	Gly	Gly	Gly	<b>Val</b> 120	Gln	Asp	Gln	Ala	Arg 125	Glu	Lys	His
	Val	Lys 130	Glu	Val	Ile	Ser	Gln 135	Leu	Thr	Gly	Val	His 140	Gly	Thr	Ser	Ser
35	Pro	Tyr	Lys	Gly	Leu	Asp	Leu	Ser	Lys	Leu	His	Glu	Thr	Leu	Arg	Thr
	145					150					155					160

	His	Thr	Arg	Leu	Val 165	Ser	Leu	Phe	Asn	Thr 170	Thr	Leu	Thr	Gly	Leu 175	His
5	Glu	Val	Ser	Ala 180	Gln	Asn	Pro	Thr	Asn 185	Cys	Trp	Ile	Cys	Leu 190	Pro	Leu
10	Asn	Phe	Arg 195	Pro	Tyr	Val	Ser	Ile 200	Pro	Val	Pro	Glu	Gln 205	Trp	Asn	Asn
77	Phe	Ser 210	Thr	Glu	Ile	Asn	Thr 215	Thr	Ser	Val	Leu	Val 220	Gly	Pro	Leu	Val
15	Ser 225	Asn	Val	Glu	Ile	Thr 230	His	Thr	Ser	Asn	Leu 235	Thr	Сув	Val	Lys	Phe 240
	Ser	Asn	Thr	Thr	Туг 245	Thr	Thr	Asn	Ser	Gln 250	Суѕ	Ile	Arg	Trp	Val 255	Thr
20	Pro	Pro	Thr	Gln 260	Ile	Val	Сув	Leu	Pro 265	Ser	Gly	Ile	Phe	Phe 270	Val	Cys
25	Gly	Thr	ser 275	Ala	Tyr	Arg	Суз	Leu 280	Asn	Gly	Ser	Ser	Glu 285	Ser	Met	Cys
	Phe	Leu 290	ser	Phe	Leu	Val	Pro 295	Pro	Met	Thr	Ile	туr 300	Thr	Glu	Gln	qsA
30	Leu 305	Tyr	Ser	Tyr	Val	11e 310	Ser	Lys	Pro	Arg	Asn 315	Lys	Arg	Val	Pro	11e 320
	Leu	Pro	Phe	Val	Ile 325	Gly	Ala	Gly	Val	Leu 330	Gly	Ala	Leu	Gly	Thr 335	Gly
35	Ile	Gly	Gly	11e 340	Thr	Thr	Ser	Thr	Gln 345	Phe	Tyr	Tyr	Lys	Leu 350	Ser	Gln

	Glu	ı Lei	Asn 355		Asp	Met	Glu	360		. Ala	Asp	Ser	: Leu 365		Thr	Le
5	Glr	370	Gln	Leu	. Asn	Ser	Leu 375		Ala	val	Val	Leu 380		Asn	Arg	Arg
10	Ala 385		ı Asp	Leu	Leu	Thr		Glu	Arg	Gly	Gly 395		Cys	Leu	Phe	Le:
	Gly	Glu	Glu	Cys	Cys 405	Tyr	Tyr	Val	Asn	Gln 410		Gly	Ile	Val	Thr 415	Glu
15	Lys	Val	Glu	Glu 420		Pro	Asp	Arg	Ile 425		Arg	Ile	Ala	Glu 430	Glu	Lev
	Arg	Asn	Thr 435	Gly	Pro	Trp	Gly	Leu 440	Leu	Ser	Arg	Trp	Met 445	Pro	Trp	Ile
20	Leu	Pro 450	Phe	Leu	Cly	Pro	Leu 455	Ala	Ala	Ile	Ile	Leu 460	Leu	Leu	Leu	Phe
25	Gly 465	Pro	Сув	Ile	Phe	Asp 470	Leu	Leu	Val	Asn	Phe 475	Val	Ser 	Ser	Arg	Ile 480
	Glu	Ala	Val	Lys	Leu 485	Gln	Met	Glu	Pro	Lys 490	Met	Gln	Ser	Lys	Thr 495	Lys
30	Ile	Tyr	Arg	Arg 500	Pro	Leu	qaA	Arg	Pro 505	Ala	Ser	Pro	Arg	<b>Ser</b> 510	Asp	Val
	Asn	Asp	Ile 515	Lys	Gly	Thr	Pro	Pro 520	Glu	Glu	Ile	Ser	Ala 525	Ala	Gln	Pro
35	Leu	Leu 530	Arg	Pro	Asn		Ala 535	Gly	ser	Ser						

(2) INFORMATIONS POUR LA SEQ ID NO: 34:

5	(i)	CAR	ACTE	RIST	IQUE	S DE	LA	SEQU	ENCE	:						
		(A	) Lo	NGUE	UR:	52 a	cide	s am	inés							
		(B	) TY	PE:	acid	e am	iné					,				
		(C	) NO	MBRE	DE I	BRIN	S: s	impl	е							
		(D	) CO	NFIG	URAT	ion:	lin	éair	9							
10	1															
	(ii)	TYPI	E DE	MOL	ECUL	E: po	epti	de								
								5								
	(iii)	HYPO	OTHE'	riqu	E: N	NC										
15	(xi)	DESC	CRIP'	rion	DE 1	LA SI	EQUE	NCE:	SEQ	ID I	10:	34:				
		Glu	Pro	Lys		Gln	Ser	Lys	Thr		Ile	Tyr	Arg	Arg	Pro	Leu
	1				5					10					15	
20	3 am	<b>3</b>	Dwa	N1 n	504	Desc	<b>3</b>	Co	3	77-3	<b>&gt;</b>		<b>~</b> 1 -	•		
20	Asp	Arg	Pro	20	ser	Pro	Arg	ser	Asp 25	vai	Asn	Asp	116	_	Gly	Thr
				20					25	,			."	30		
	Pro	Pro	Glu	Glu	Ile	Ser	Ala	Ala	Gln	Pro	Len	Leu	Ara	Pro	Asn	Ser
			35					40				204	45			Ser
25																
	Ala	Gly	Ser	Ser												
		50														
30	(2) INFOR	ITAMS	ONS	POUF	LA	SEQ	ID N	10: 3	15:							
	(i)	CARA	CTEF	RISTI	QUES	DE	LA S	EQUE	NCE:							
		(A)	LON	IGUEU	IR: 4	8 ac	ides	ami	nés							
		(B)	TYF	E: a	cide	ami	.né									
35		(C)	NOM	BRE	DE B	RINS	: si	.mple	•							

(D) CONFIGURATION: linéaire

	(11)	TYPE DE MO	OLECULE: pepti	.de			
5	(iii)	нүротнетіс	QUE: NON		· ·		
J	(xi)	DESCRIPTIO	ON DE LA SEQUE	NCE: SEQ ID	NO: 35:		
	Met 1	Leu Met Th	r Ser Lys Ala 5	Pro Leu Leu 10	Arg Lys Ser	Gln Leu H 15	lis
10	Asn	Leu Tyr Ty 20	r Ala Pro Ile	Gln Gln Glu 25	Ala Val Arg	g Ala Val V 30	'al
15	Gly	Gln Pro Pr 35	o Gln Gln His	Leu Gly Phe	Pro Val Glu	Met Gly A	qa.

C12Q1/68

C07K16/10

G01N33/569

According to International Patent Classification (IPC) or to both national classification and IPC

#### B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols) IPC 6 C07K C12N

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Electronic data base consulted during the international search (name of data base and, where practical, search terms used)

Category °	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
X	WO 97 06260 A (BIO MERIEUX ; PERRON HERVE (FR); BESEME FREDERIC (FR); BEDIN FREDER) 20 February 1997 cited in the application see the whole document	1-4,6-20
X	PERRON H ET AL: "MOLECULAR IDENTIFICATION OF A NOVEL RETROVIRUS REPEATEDLY ISOLATED FROM PATIENTS WITH MULTIPLE SCLEROSIS" PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF USA, vol. 94, July 1997, pages 7583-7588, XP002062853	1-4,7-20
	see the whole document	, D , An
A	WO 94 11514 A (ASTA MEDICA AG) 26 May 1994 see abstract claims	15,17
	-/	

Further documents are listed in the continuation of box C.	X Patent family members are listed in annex.
° Special categories of cited documents :	
"A" document defining the general state of the art which is not considered to be of particular relevance	"T" later document published after the international filing date or priority date and not in conflict with the application but clied to understand the principle or theory underlying the invention
"E" earlier document but published on or after the international filing date  "L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another	"X" document of particular relevance; the claimed Invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken atone
citation or other special reason (as specified)  "O" document referring to an oral disclosure, use, exhibition or other means	"Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such document.
"P" document published prior to the international filing date but later than the priority date claimed	ments, such combination being obvious to a person skilled in the art.  "&" document member of the same patent family
Date of the actual completion of theinternational search	Date of mailing of the international search report
22 September 1998	29/09/1998
Name and mailing address of the ISA  European Patent Office, P.B. 5818 Patentiaan 2	Authorized officer
NL - 2280 HV Rijswijk Tel. (+31-70) 340-2040, Tx. 31 651 epc ni, Fax: (+31-70) 340-3016	Panzica, G

1

PCT/FR 98/01442

	tion) DOCUMENTS CONSIDERE	
Category °	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
1	WO 93 20188 A (BIO MERIEUX) 14 October 1993	
	EP 0 731 168 A (BIO MERIEUX) 11 September 1996	
	·	
ĺ		
İ		
,		
. *		
		·
		• []
		10.

Form PCT/ISA/210 (continuation of second sheet) (July 1992)

1

information on patent family members

PCT/FR 98/01442

5			<del></del>		
Patent docume cited in search re		ublication date		Patent family member(s)	Publication date
WO 9706260	A	20-02-1997	FR	2737500 A	07-02-1997
	•		AU	6823296 A	05-03-1997
			BG	101355 A	30-12-1997
			BR	9606566 A	30-12-1997
			CZ	9701357 A	17-06-1998
			EP	0789077 A	13-08-1997
		•	NO	971493 A	03-06-1997
			PL	319512 A	18-08-1997
WO 9411514	A	26-05-1994	GB	2273099 A	08-06-1994
WO 9320188	Α	14-10-1993	FR	2689519 A	08-10-1993
			FR	2689520 A	08-10-1993
			CA	2110702 A	14-10-1993
			CA	2110703 A	14-10-1993
	,		, EP	0587873 A	23-03-1994
			EP	0592636 A	20-04-1994
			FR	2689521 A	08-10-1993
			WO	9320189 A	14-10-1993
			US	5585262 A	17-12-1996
			US 	5650318 A	22-07-1997
EP 0731168	Α	11-09-1996	FR	2731356 A	13-09-1996
			AU	5007396 A	02-10-1996
			BR	9605926 A	02-09-1997
			CA	2171242 A	10-09-1996
			CZ	9603287 A	12-03-1997
			WO	9628552 A	19-09-1996
			JP	8322579 A	10-12-1996
			NO	964760 A	08-11-1996
			PL	317200 A	17-03-1997

C12Q1/68

C07K16/10

G01N33/569

Selon la classification internationale des brevets (CIB) ou à la tois selon la classification nationale et la CIB

## B. DOMAINES SUR LESQUELS LA RECHERCHE A PORTE

Documentation minimale consultée (système de classification suivi des symboles de classement) CIB 6 C07K C12N

Documentation consultée autre que la documentationminimale dans la mesure où ces documents relèvent des domaines sur lesquels a porté la recherche

Base de données électronique consultée au cours de la recherche internationale (nom de la base de données, et si cela est réalisable, termes de recherche utilisés)

Catégorie °	Identification des documents cités, avec, le cas échéant, l'indication des passages pertinents	
	cas echeant, rindication des passages pertinents	no. des revendications visées
X	WO 97 06260 A (BIO MERIEUX ;PERRON HERVE (FR); BESEME FREDERIC (FR); BEDIN FREDER) 20 février 1997 cité dans la demande voir le document en entier	1-4,6-20
X	PERRON H ET AL: "MOLECULAR IDENTIFICATION OF A NOVEL RETROVIRUS REPEATEDLY ISOLATED FROM PATIENTS WITH MULTIPLE SCLEROSIS" PROCEEDINGS OF THE NATIONAL ACADEMY OF SCIENCES OF USA, vol. 94, juillet 1997, pages 7583-7588, XP002062853 voir le document en entier	1-4,7-20
A	WO 94 11514 A (ASTA MEDICA AG) 26 mai 1994 voir abrégé * revendications *	15,17

X Voir la suite du cadre C pour la finde la liste des documents	X Les documents de familles de brevets sont indiqués en annexe
° Catégories spéciales de documents cités:	
"A" document définissant l'état général de latechnique, non considéré comme particulièrement pertinent "E" document antérieur, mais publié à la date dedépôt international ou après cette date "L" document pouvant jeter un doute sur une revendcation de priorité ou cité pour déterminer la date depublication d'une autre citation ou pour une raison spéciale (telle qu'indiquée) "O" document se référant à une divulgation orale, à un usage, à une exposition ou tous autres moyens "P" document publié avant la date de dépôtinternational, mais postérieurement à la date de priorité revendiquée	"T" document ultérieur publié après ladate de dépôt international ou la date de priorité et n'appartenenant pas à l'état de la technique pertinent, mais cité pour comprendre le principe ou la théorie constituant la base de l'invention revendiquée ne peut être considérée comme nouvelle ou comme impliquant une activité inventive par rapport au document considéré isolément "Y" document particulièrement pertinent; l'invention revendiquée ne peut être considérée comme impliquant une activité inventive lorsque le document est associé à un ou plusieurs autres documents de même nature, cette combinaison étant évidente pour une personne du métier
Date à laquelle la recherche internationale a étéeffectivement achevée	Dete d'expédition du présent rapport de recherche internationale
22 septembre 1998	29/09/1998
Nom et adresse postale de l'administrationchargée de la recherche internationale Office Européen des Brevets, P.B. 5818 Patentiaan 2 NL - 2280 HV Rijswijk	Fonctionnaire autorisé
Tel. (+31-70) 340-2040, Tx. 31 651 epo nl, Fax: (+31-70) 340-3016	Panzica, G

1

CT/ER 98/01442

	CUMENTS CONSIDERES COM RTINENTS  dentification des documents cités avec le cas échéant l'indication des		
	dentification des documents cités, avec,le cas échéant, l'indicationdes pa	ssages pertinents	no. des revendications visées
	WO 93 20188 A (BIO MERIEUX) 14 octobre 1993		
	-		
	EP 0 731 168 A (BIO MERIEUX) 11 septembre 1996	•	
,,,,,,,	•		
-			
		•	8
		•	
	.ه.		
	**		
	•		
	•		
			`.

Renseignements re. 🕒 aux membres de familles de brevets

PCT/5R 98/01442

			PCI/KR 98/01442			
au rap	ument brevet di port de recherc	té che	Date de publication	Me fam	embre(s) de la ille de brevet(s)	Date de publication
WO	9706260	Α	20-02-1997	FR	2737500 A	07-02-1997
				AÜ	6823296 A	05-03-1997
				BG	101355 A	
			,	BR	9606566 A	30-12-1997
				CZ	9701357 A	30-12-1997
				EP	0789077 A	17-06-1998
				NO	971493 A	13-08-1997
				PL	319512 A	03-06-1997
			~~	L	219512 H	18-08-1997
WO_	9411514	Α .	26-05-199 <b>4</b>	GB	2273099 A	08-06-1994
MO	WO 9320188	Α	14-10-1993	FR	2689519 A	08-10-1993
			,	FR	2689520 A	08-10-1993
				CA	2110702 A	14-10-1993
				CA	2110703 A	14-10-1993
				EP	0587873 A	23-03-1994
				EP	0592636 A	20-04-1994
				FR	2689521 A	08-10-1993
				WO	9320189 A	14-10-1993
				US	5585262 A	17-12-1996
				US	5650318 A	22-07-1997
EP 0731168 A	Α	11-09-1996	FR	2731356 A	13-09-1996	
			AU	5007396 A	02-10-1996	
			BR	9605926 A	02-09-1997	
			CA	2171242 A	10-09-1996	
			CZ	9603287 A	12-03-1997	
			WO	9628552 A	19-09-1996	
			JP	8322579 A	10-12-1996	
				NO	964760 A	08-11-1996
				PL	317200 A	17-03-1997